



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ
BRNO UNIVERSITY OF TECHNOLOGY



FAKULTA STAVEBNÍ
ÚSTAV VODNÍHO HOSPODÁŘSTVÍ KRAJINY

FACULTY OF CIVIL ENGINEERING
INSTITUTE OF LANDSCAPE WATER MANAGEMENT

STŘEDNĚDOBÁ PŘEDPOVĚĎ PRŮTOKŮ VODY MĚRNÝM PROFIEM TOKU

LONG TERM DISCHARGE PREDICTION IN RIVER HYDROMETRIC PROFILE

DIPLOMOVÁ PRÁCE
DIPLOMA THESIS

AUTOR PRÁCE
AUTHOR

BC. MILAN ŠELEPA

VEDOUCÍ PRÁCE
SUPERVISOR

Ing. DANIEL MARTON, Ph.D.

BRNO 2015



VYSOKÉ UČENÍ TECHNICKÉ V BRNĚ FAKULTA STAVEBNÍ

Studijní program	N3607 Stavební inženýrství
Typ studijního programu	Navazující magisterský studijní program s prezenční formou studia
Studijní obor	3607T027 Vodní hospodářství a vodní stavby
Pracoviště	Ústav vodního hospodářství krajiny

ZADÁNÍ DIPLOMOVÉ PRÁCE

Diplomant	Bc. Milan Šelepa
Název	Střednědobá předpověď průtoků vody měrným profilem toku
Vedoucí diplomové práce	Ing. Daniel Marton, Ph.D.
Datum zadání diplomové práce	24. 3. 2014
Datum odevzdání diplomové práce	16. 1. 2015
V Brně dne 24. 3. 2014	

.....
prof. Ing. Miloš Starý, CSc.
Vedoucí ústavu

.....
prof. Ing. Rostislav Drochytka, CSc., MBA
Děkan Fakulty stavební VUT

Podklady a literatura

Starý M., Modul 01 Hydrologie, VUT FAST V Brně, Brno 2005

Starý M., Modul 03 Hydrologie - Návod do cvičení, VUT FAST V Brně, Brno 2005

Chng et al., Long-Term Prediction of Discharges in Manwan Reservoir Using Artificial Neural Network Models, Advances in Neural Networks, Second International Symposium on Neural Networks, Chongqing, China 2005

MATLAB Tutorials and Learning Resources

Link: http://www.mathworks.com/academia/student_center/tutorials/launchpad.html

MATLAB and Simulink Tutorials

Link: http://www.mathworks.com/academia/student_center/tutorials/

Zásady pro vypracování

Ze zadání diplomové práce je zcela jasný i cíl práce, kterým je sestavení střednědobé předpovědi průtoků v měrném profilu toku.

Jako vstupní data pro sestavení předpovědi je časová řada průměrných měsíčních průtoků.

Hlavním úkolem diplomanta bude pomocí metod umělé inteligence (neuronových sítí) sestavit předpovědní model průtoků vody v korytě toku a úspěšnost předpovědi následně vyhodnotit pomocí odpovídajících metod.

Předepsané přílohy

Licenční smlouva o zveřejňování vysokoškolských kvalifikačních prací

.....

Ing. Daniel Marton, Ph.D.
Vedoucí diplomové práce

Abstrakt

Diplomová práce je zaměřena na sestavení střednědobých předpovědí průměrných měsíčních průtoků vody měrným profilem toku za účelem optimalizace řízení nádrže a vodohospodářských soustav nádrží. Průtoky byly předpovídaný pomocí metody umělých neuronových sítí. Předpovězené průtoky byly statisticky vyhodnoceny odpovídajícími koeficienty a následně porovnávány s naměřenými hodnotami průtoků pro dané měrné profily toku.

Klíčová slova

Předpověď průtoků, průměrný měsíční průtok, umělé neuronové sítě, Matlab, koeficient determinace, nádrže, soustavy nádrží

Abstract

The diploma thesis is focused on the long term prediction of mean monthly flows in hydrometric profile for purposes of reservoir control optimization and optimization of reservoir systems. Discharges were predicted using by artificial neural network method. Predicted flows were statistically evaluated by relevant coefficients and then compared with the measured flows for given river hydrometric profiles.

Keywords

Discharge Prediction, Mean Monthly Discharge, Artificial Neural Network, Matlab, Coefficient of Determination, Open Water Reservoir, Reservoir System

Bibliografická citace

Bc. Milan Šelepa, *Střednědobá předpověď průtoků vody měrným profilem toku*. Brno, 2014. 82 s. Diplomová práce. Vysoké učení technické v Brně, Fakulta stavební, Ústav vodního hospodářství krajiny. Vedoucí práce Ing. Daniel Marton, Ph.D.

Prohlášení:

Prohlašuji, že jsem diplomovou práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje.

V Brně dne 16.1.2015

.....
podpis autora
Bc. Milan Šelep

Děkuji svému vedoucímu diplomové práce Ing. Danielovi Martonovi, Ph.D. za odborné vedení, cenné rady, vstřícný přístup, poskytnutí odborné literatury a softwaru pro řešení diplomové práce. Děkuji také svým rodičům za podporu při studiu.

OBSAH

1. ÚVOD	3
2. SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY	4
3. CÍL PRÁCE	6
4. POUŽITÉ METODY	7
4.1. Neuronové sítě	7
4.1.1. Normalizace dat	7
4.1.2. Umělý neuron	8
4.1.3. Topologie sítě	9
4.2. Obecný postup vyhotovení předpovědi	9
4.3. Hybridní model	10
4.4. Vyhodnocení předpovědi	12
4.4.1. Koeficient korelace	12
4.4.2. Koeficient determinace	14
4.4.3. Nash-Sutcliffeův koeficient	15
4.4.4. Index shody	16
5. PRAKTICKÁ APLIKACE	17
5.1. Popis území	18
5.1.1. Měrný profil Dalečín	20
5.1.2. Měrný profil Skryje	21
5.2. Popis a příprava dat	22
5.2.1. Normalizace dat	24
5.2.2. Příprava dat k načtení do Neural Network Toolbox	25
5.3. Práce s Neural Network Toolbox	27
5.3.1. Nastavení neuronové sítě	28
5.3.2. Typ sítě	29
5.3.3. Tréninkové funkce	30
5.3.4. Trénování neuronové sítě a simulace hodnot	30
5.4. Nalezení optimální předpovědi průměrných měsíčních průtoků	35
5.4.1. Stanovení optimální předpovědi vzad pro klasický model neuronových sítí	36
5.4.2. Stanovení optimální předpovědi vpřed pro klasický model neuronových sítí	43
5.4.3. Stanovení optimální předpovědi vzad a vpřed pro hybridní model neuronových sítí	45

5.5. Sestavení předpovědi pro aplikaci na vodohospodářskou soustavu	49
5.5.1. Předpovědi průměrných měsíčních průtoků pro měrný profil Dalečín	50
5.5.2. Předpovědi průměrných měsíčních průtoků pro měrný profil Skryje	55
6. SHRUTÍ VÝSLEDKŮ	62
6.1. Porovnání předpovězených průtoků klasickým a hybridním modelem.....	63
6.2. Porovnání předpovězených průtoků klasickým modelem a modelem typu ARMA	69
7. ZÁVĚR.....	76
8. SEZNAM POUŽITÝCH ZDROJŮ	78
SEZNAM OBRÁZKŮ.....	80
SEZNAM TABULEK	81
SEZNAM PŘÍLOH	82

1. ÚVOD

Jedním ze základních důvodů pro práci spojenou s hydrologickou předpovědí, zejména s předpovědí průtoků v toku jsou postupné socio-ekonomické změny vyvolané změnou klimatu a častější potřeba efektivního nakládání s vodními zdroji. V hydrologii je pak příčinou častější výskyt hydrologických extrémů sucha a povodní. Využitím moderních technických prostředků a poznatků ve vědě a výzkumech je snaha těmto extrémům předcházet, být na ně dostatečně připravený, včas reagovat a minimalizovat tak ekonomické ztráty, které mohou jejich následkem vzniknout.

Se změnami klimatu také souvisí přerozdělení srážek v průběhu hydrologického roku. To znamená množství srážek spadající na dílčí povodí a přeměňující se na povrchový odtok. Toto vede k úvahám o snižování velikostí průtoků v říční síti. V budoucnu se očekává pokles dlouhodobých průměrných průtoků Q_a přibližně o 20 až 40 % [1].

Při zmínění pojmu hydrologický extrém si většina lidí představí povodně, které se v ČR objevily v poslední době hlavně v letech 1997, 2002, 2009 a 2013. Odborná veřejnost se po těchto událostech zabývala převážně návrhy protipovodňových opatření. Podobným problémem jsou také stále častěji se objevující suchá období, například roky 2012, 2013 a 2014 jsou hodnoceny za výraznější v souvislosti se suchem. Léto a podzim 2012 byla hodnocena jako extrémně málo vodná období. Zima roku 2013/2014 byla výjimečná nedostatkem zásoby vody ve sněhové pokrývce a následným nedostatkem povrchově akumulované vody v nádržích.

Z těchto důvodů se nyní začíná prosazovat snaha o zlepšení řízení vodohospodářských soustav nádrží. Trendem ve světě je predikce průměrných měsíčních průtoků jako prostředek pro optimalizaci řízení nádrží. Na základě optimalizačních a predikčních metod je snaha o vytváření pravidel pro řízení nádrží. K tomuto účelu se právě dají využít předpovědi průměrných měsíčních průtoků v říčních korytech, kdy predikce průměrných měsíčních průtoků uvažujeme jako přítoky do nádrže, nebo do systému nádrží.

Jedním z moderních a stále hojně využívaným nástrojem vhodným k predikci průměrných měsíčních průtoků ve vodoměrném profilu toku je využití modelů umělých neuronových sítí.

2. SOUČASNÝ STAV ŘEŠENÉ PROBLEMATIKY

Umělou inteligencí a problematikou neuronových sítí se začali odborníci zabývat již v první polovině 20. století. Schopnost učení sítě navrhl Donald Hebb již v roce 1949. K dalšímu vývoji neuronových sítí přispěl Frank Rosenblatt, který vyvinul třídu neuronů nazývaných "Perceptrony". Poté ve výzkumu neuronových sítí nastal menší útlum a zájem o neuronové sítě se na několik let výrazně zmenšil. V roce 1982 publikoval John Hopfield článek o neuronových sítích, kterým znovu podnítil vědce, aby se blíže zabývali neuronovými sítěmi. Dalším velkým pokrokem byla aplikace teorie zpětného šíření (back-propagation) při učení neuronové sítě, kterou uvedli ve svém článku Sejnowski a Rosenberg v roce 1988. Význam neuronových sítí dále rostl s využitím neustále se zdokonalující výpočetní techniky.

Pro neuronové sítě bylo nalezeno mnoho způsobů využití. Lze je použít ve zdravotnictví, dopravní signalizaci, ekonomii, ale také ve vodním hospodářství. V současnosti se ve vodním hospodářství používají predikce průměrných měsíčních průtoků k zefektivnění řízení soustav nádrží. Jednou z variant je předpovídání průtoků pomocí modelu, který pracuje s neuronovými sítěmi.

V České republice se využitím neuronových sítí ve vodním hospodářství zabýval například Miloš Starý ve své habilitační práci - Užití neuronových sítí v aplikované hydrologii [2]. V práci byly neuronové sítě použity pro předpovídání kulminačních průtoků v povodí toku Ostravice se závěrovým profilem Šance pomocí programů Hydrog a Brain Maker. Dále pro předpovídání hydrogramů povodňových vln v povodí toku řeky Morávky se závěrovým profilem (hrází) Morávka. Na naší škole se blíže zabývají problematikou předpovědních modelů pro účely řízení vodohospodářské soustavy Pavel Menšík, Miloš Starý a Daniel Marton. V roce 2014 na konferenci ITISE prezentovali článek na téma Použití předpovědních modelů průměrných měsíčních průtoků pro operativní řízení zásobní funkce vodních nádrží [3]. Zmínili zde vizi o zlepšení původních metod řízení nádrží inteligentním způsobem řízením. Popisují algoritmus vycházející z adaptivního operativního řízení, který využívá střednědobé předpovědi přítoků vody do nádrží. Hodnoty řízených odtoků získávali optimalizací, která vychází z evolučních algoritmů.

Dále ve spolupráci s Milošem Starým uvedl Jiří Sázel metodu předpovídání průtoků v článku Střednědobé předpovědi průtoků povrchových toků [4]. Popisuje metodu předpovídání průtoků částečnou grafickou metodou odchylek, kdy dochází k porovnání aktuálních průtoků s historickými, neboli také modelem podobnosti. Průtoky předpovídal na základě podobnosti průtoků v historii společně s použitím srážkové a teplotní řady.

Na Pražské ČVUT se touto problematikou zabýval například Pavel Fošumpaur v článku - Použití umělých neuronových sítí pro operativní předpovědi říčních průtoků [5]. Autor porovnává přesnost předpovědí dvou modelů na horním povodí Sázavy po profil Chlístov. Jedná se o porovnání lineárního modelu ARMAX s nelineárním neuronovým modelem.

Ze slovenských autorů je možné zmínit například Danielu Svetlíkovou a její článek Hybridný model priemerných mesačných prietokov pre povodie horného Hrona [6]. Cílem práce byla tvorba hybridního (deterministicko – stochastického) modelu, který je sestaven kombinací hydrologického modelu KVHK a matematického modelu časových řad. Pro simulaci průměrných měsíčních průtoků byly použity modely třídy ARMA. Hybridní model byl zkoušen pro stanici Banská Bystrica – Hron.

V zahraničí zmínili Amir F. Atiya a kol. v článku A Comparison Between Neural-Network Forecasting Techniques - Case Study: River Flow Forecasting [7] aplikování neuronových sítí pro předpovědi průtoků na toku Nil v Egyptě. Dalším cílem jejich práce bylo porovnat několik modelů pracujících pomocí neuronových sítí, kdy jako kontrolní měřítko využili metodu časových řad. Porovnávali mezi třemi různými způsoby: přímou metodou, rekurzivní metodou a rekurzivní metodou trénování pomocí zpětného šíření prostřednictvím časového schéma. Problematicou předpovídání průtoků pomocí neuronových sítí se také zabývali Chuntian Cheng a kol. Blíže to popsali v článku Long-Term Prediction of Discharges in Manwan Reservoir Using Artificial Neural Network Models [8]. Cílem výzkumu bylo vyzkoušet použitelnost modelů umělých neuronových sítí se strukturou učení metodou zpětného šíření pro předpovědi průměrných přítoků do nádrže Manwan. Pro předpovídání byla použita třívrstvá neuronová síť se čtyřmi vstupními, čtyřmi skrytými neurony a jedním výstupním neuronem. Předmětem zkoušení bylo vhodné nastavení tréninkových parametrů a délka předpovědi, která se pohybovala mezi denními a měsíčními průměrnými průtoky. Nakonec provedli vyhodnocení výsledků pomocí koeficientu korelace a posouzení vhodnosti předpovědního modelu.

3. CÍL PRÁCE

Cílem diplomové práce bylo stanovení střednědobé předpovědi průtoků vody měrným profilem toku. Předpovědi byly získávány pomocí metod umělé inteligence za použití neuronových sítí. Předpovědní model byl aplikován v měrném profilu Dalečín, který se nachází na vodním toku Svratka a v měrném profilu Skryje, který se nachází na vodním toku Bobrůvka. Cíle práce lze rozdělit do dvou rovin.

Prvním cílem bylo nalezení způsobu předpovídání průměrných měsíčních průtoků pomocí neuronových sítí. Najít cestu k vhodným předpovědím průtoků a zjistit správný postup při volbě délky předpovědi a dosazování vstupních dat. Byly testovány dva druhy předpovědních modelů. První byl klasický model neuronových sítí a druhý byl tzv. hybridní model neuronových sítí, který používá jako vstupní hodnoty, společně s historickými řadami průtoků, řady uměle vygenerované programem LRM soft.

V druhé rovině byla metoda aplikována na sestavení předpovědí průtoků ve vybraných vodoměrných profilech a ve vybraném období, které dále sloužily pro účely optimalizace řízení odtoku vody ze systému nádrží. Sestavené předpovědi byly také porovnány s hodnotami průtoků předpovězenými v bakalářské práci.

4. POUŽITÉ METODY

4.1. Neuronové sítě

V minulosti byla teorie o modelu založeného na porozumění a napodobení chování mozku a soustavy nervových tkání. Podle vzoru fungování lidského mozku byl vytvořen model umělých neuronových sítí. Neuronové sítě lze obecně považovat za nelineární regresní model. Podobně jako u lidského mozku, kde jsou všechny neurony mezi sebou propojeny, dochází ke komunikaci mezi nimi pomocí impulsů. Je přenášen vstupní signál s určitou vahou, který je dále blokován nebo propouštěn s určitou silou do následující vrstvy neuronů. Propustnost signálu je přímo závislá na aktivační funkci. Pokud je aktivační funkce kladná propustí signál dále. Významným prvkem neuronových sítí je jejich schopnost učit se, kdy již jednou natrénovaná síť pracuje na základě podobných postupů, jaké použila v předchozím případě. To znamená, že síť je schopná správně reagovat také na vstupy, které předtím nebyly součástí tréninkových dat.

4.1.1. Normalizace dat

Normalizace nebo také standardizace dat je postup převedení dat do požadovaného intervalu. Interval normalizovaných dat se obvykle pohybuje blízko nule. Pro neuronové sítě se používají intervaly normalizovaných dat v rozmezí $\langle 0,1 \rangle$ nebo $\langle -1,1 \rangle$. Takové intervaly jsou vhodné při trénování sítě, kdy je použita například sigmoidální přenosová funkce. Trénování sítě je zjednodušeno a zrychleno, když jsou vstupní data symetrická podle daného intervalu. Výstupní data jsou pak zpětně transformována na hodnoty průtoků. Normalizace dat lze provádět v matici vstupních dat buď po směru sloupců, nebo po směru řádků pomocí rovnice (1).

$$x = Q_i - \frac{(Q_{\max} + Q_{\min})/2}{(Q_{\max} - Q_{\min})/2} \quad (1)$$

kde: Q_i – hodnota průtoku v čase,

Q_{\min} – minimální hodnota průtoku v daném řádku nebo sloupci

Q_{\max} – maximální hodnota průtoku v daném řádku nebo sloupci

4.1.2. Umělý neuron

Umělá neuronová síť, která je vytvořená po vzoru biologické neuronové sítě, obsahuje síť mezi sebou propojených neuronů. Pohled na jeden vyjmutý neuron je na obr. 1. Do tohoto neuronu směřují vstupní signály (spojnice) z ostatních neuronů, které obsahují synoptické váhy. Ze vstupního signálu vynásobeného synoptickou vahou je odečtena prahová hodnota a zbytek je násoben přenosovou funkcí. To vše lze shrnout pomocí rovnice (2). Výpočtem je vygenerována výstupní hodnota, která je dále převedena jako vstupní hodnota do následujícího neuronu.

$$Y_i = f \cdot \left(\sum_{i=1}^n X_i \cdot W_i - \Theta \right) \quad (2)$$


kde: Y_i – velikost výstupního signálu,

f – přenosová funkce,

X_i – velikost vstupního signálu,

W_i – velikost synoptické váhy,

Θ – prahová hodnota.



Obr. 1 Schéma umělého neuronu.

4.1.3. Topologie sítě

Sestavení topologie (struktury) sítě je dalším důležitým prvkem pro dosažení správné funkčnosti neuronové sítě. Jde především o volbu optimálního počtu neuronů a optimálního počtu skrytých vrstev neuronové sítě. Návrhy množství neuronů a skrytých vrstev nelze volit pomocí určitého univerzálního pravidla nebo postupu. Pro každou řešenou úlohu nebo problém je způsob nastavení struktury sítě individuální. Proto optimální počet neuronů nebo skrytých vrstev je třeba hledat experimentálně. Buď lze zvolit počet skrytých vrstev a počet neuronů v ní obsažených jako průměrnou hodnotu z počtu vstupních a výstupních neuronů, nebo lze začít s malým počtem neuronů a postupně jej navyšovat a souběžně sledovat přesnost natrénované sítě. Pokud síť obsahuje malý počet neuronů, může nastat problém, kdy schopnost popsat závislosti bude nižší. Naopak když je počet parametrů sítě větší než počet vzorů pro trénování, tak může dojít k tzv. přetrénování sítě. Příliš mnoho skrytých neuronů může způsobit, že si neuronová síť zapamatuje vzory, místo aby se podle nich učila. Dalším z problémů při natrénování sítě, může být příliš malý počet tréninkových vzorů, kdy dojde sice k natrénování sítě, ale ne správně. Při trénování je možnost vzniku libovolného vztahu mezi vstupy a výstupy, jak bylo zmíněno ve skriptech Hydrologie [9].

V této práci byla použita vícevrstvá neuronová síť se zpětným šířením učení (feed-forward back-propagation). Během trénování se v síti mění hodnoty synoptických vah. Proces korekce synoptických vah u této metody probíhá dopředně a zároveň zpětně od výstupní vrstvy po vrstvu vstupní. Při trénování sítě jsou vypočítávány odchylky mezi zadanými výstupními signály a vypočítanými signály. Rozdíl celkové chyby je získán odečtením součtu čtverců vzorových chyb od součtu čtverců vypočtených chyb. Opakovaná korekce vah při trénování je ukončena při dosažení optimální celkové chyby.

4.2. Obecný postup vyhotovení předpovědi

Postup generování a rozsah generovaných dat pomocí modelu neuronových sítí byl stanoven experimentální metodou. Ta spočívala v nalezení vhodného počtu měsíců použitých jako vstupní měsíce a také nalezení vhodného počtu předpovídaných měsíců. Zjednodušeně řečeno nalézt optimální délku předpovědi vzad odpovídající vhodnému počtu vstupních měsíců pro předpověď. Dále pak nalézt optimální délku předpovědi udanou vhodným počtem předpovídaných měsíců dopředu. Postup byl prováděn od jednoho měsíce a následně symetricky navyšován. Vhodné počty měsíců byly stanoveny při předpovídání klasickým

modelem neuronových sítí i při předpovídání hybridním modelem. Hledání optimálního počtu měsíců bylo rozděleno do dvou částí.

Nejprve byl testován optimální počet měsíců použitých jako vstupy pro předpovídání. To znamená, že byl nastaven pouze jeden předpovídaný měsíc vpřed a počet vstupních měsíců byl nejprve zvolen jeden a dále byl počet vstupních měsíců postupně navyšován až na dvanáct měsíců. Celý proces byl opakován s posunem o jeden měsíc, až do té doby dokud nebyl předpovězen celý rok. Posouzení vhodného počtu vstupních měsíců bylo provedeno statistickým vyhodnocením. Pro vyhodnocování bylo použito koeficientů korelace, determinace, Nash-Sutcliffeova koeficientu a indexu shody. Byl proveden součet statistických koeficientů stanovených z každé měsíční předpovědi odpovídající dvanácti posunům, tak aby byl předpovězen celý rok. Pomocí maximální hodnoty sumy koeficientů byl následně stanoven vhodný počet vstupních měsíců.

Obdobným způsobem byl stanoven i počet předpovídaných měsíců vpřed, kdy na již stanovený počet vstupních měsíců vzad, byly pro předpovědi vpřed postupně navyšovány předpovězené měsíce od jednoho měsíce až na dvanáct měsíců. Pro každý posun respektive navýšení předpovídaného měsíce byl proveden součet koeficientů odpovídající dvanácti rotacím v průběhu celého roku. Z každé sumy koeficientů pro danou délku předpovědi vpřed byl vypočítán průměr a nejvyšší hodnota průměru sum koeficientů. Pro jednotlivé délky předpovědí pak nejvyšší hodnota průměru sum koeficientů udávala optimální délku předpovědi vpřed.

4.3. Hybridní model

Společně s klasickým předpovědním modelem umělých neuronových sítí byl v této práci zkoušen tzv. hybridní předpovědní model neuronových sítí. Hybridní model předpovídá průměrné měsíční průtoky na stejném principu jako klasický model. Pro přehlednost v diplomové práci je hybridním modelem nazván model, který používá jako dodatečná vstupní data uměle generované hodnoty průtokových řad. To znamená, že tréninková matice vstupních hodnot je rozšířena o uměle vytvořené hodnoty průměrných měsíčních průtoků. Tento přístup umožňuje vygenerovat libovolně dlouhou řadu vstupních dat pomocí programu LRM soft.

Program LRM soft je určen ke generování umělých průtokových řad průměrných měsíčních průtoků pomocí lineárního regresního modelu [10]. Generátor je založen na standardním postupu generování umělých průtokových řad popsanych v [9]. Kdy je

nejprve odstraněna šikmost hodnot průtoků pomocí adekvátního postupu, a hodnoty průtoků jsou transformovány na hladinu Y . V dalším kroku jsou hodnoty průtokové řady transformovány na hladinu odpovídající normálnímu normovanému rozdělení, tzv. hladina generování Z . Na hladině generování Z je pak uplatněn samotný princip generátoru umělých průtokových řad, založený na metodě lineárního regresního modelu. Princip generování popsal Kos v roce 1969 [11] a vychází z uplatnění rovnice (3).

$$h_i = c_{1,m} \cdot h_{i-1} + c_{2,m} \cdot h_{i-2} + \dots + c_{dv,m} \cdot h_{i-dv} + d_i \cdot e_m \quad (3)$$

kde: $C_{j,m}$ – regresní koeficienty lineárního regresního modelu pro $j = 1$,

kde: dv je popsán délkou Markovova řetězce,

h_{i-j} – hodnoty umělých průtoků pro $j = 1, \dots, dv$,

d_i – náhodná čísla z intervalu daného normálním standardním rozdělením,

e_m – rozptyl lineárního regresního modelu daný rovnicí (4).

$$e_m = 1 - (c_{1,m} \cdot b_{1,dv+1} + c_{2,m} \cdot b_{2,dv+1} + \dots + c_{dv,m} \cdot b_{dv,dv+1}) \quad (4)$$

kde: $C_{j,m}$ – regresní koeficienty lineárního regresního modelu pro $j = 1$,

kde: dv je popsán délkou Markovova řetězce,

$b_{j,dv+1}$ – prvky pravé strany matice, řešící regresní koeficienty $c_{j,m}$.

Po uplatnění rovnic generátoru umělých hodnot průtoků je nutno provést zpětnou transformaci z hladin Z na hladinu Y a následně na hodnoty průtoků Q_i . To je provedeno pomocí rovnice (5).

$$Q_i = \exp(h_i \cdot s_m + Q_m) + Q_{\min} \quad (5)$$

kde: h_i – i -tá generovaná hodnota průtoků na hladině Z ,

s_m – směrodatná odchylka průtoků v daném měsíci m ,

Q_m – průměrná hodnota průtoků v daném měsíci m ,

Q_{\min} – minimální hodnota průtoků.

4.4. Vyhodnocení předpovědí

Pro posouzení úspěšnosti hydrologických předpovědí se ve vodním hospodářství obvykle používá koeficient korelace a koeficient determinace. V diplomové práci pro vyhodnocení úspěšnosti předpovědi byl dále použit Nash-Sutcliffeův koeficient a Index shody.

4.4.1. Koeficient korelace

Koeficient korelace r značí míru lineární vazby mezi dvěma soubory [9]. Výpočet koeficientu korelace je proveden pomocí rovnic (6), (7), (8).


$$r = \frac{\sum \Delta X \cdot \Delta Y}{\sqrt{\sum \Delta X^2 \cdot \sum \Delta Y^2}} \quad (6)$$

$$\Delta X = X_i - \bar{X} \quad (7)$$


$$\Delta Y = Y_i - \bar{Y} \quad (8)$$

kde: X_i – naměřená hodnota průtoku v čase,
 \bar{X} – průměr z naměřených hodnot průtoků,
 Y_i – předpovězená hodnota průtoku v čase,
 \bar{Y} – průměr z předpovězených hodnot průtoků.


Úspěšnost předpovědi se vyhodnocuje podle velikosti koeficientu korelace r . Koeficient korelace se nachází v intervalu $<-1;1>$. Čím víc se hodnota r blíží k -1 nebo k 1, tak tím silnější je vazba mezi dvěma vyhodnocovanými soubory. Když se hodnota r blíží k nule, tak je vazba mezi vyhodnocovanými soubory nejslabší.



Obr. 2 Koeficient korelace - nejlepší funkce.



Obr. 3 Koeficient korelace - nejhorší funkce.



Obr. 4 Koeficient korelace - nejlepší funkce.

4.4.2. Koeficient determinace

Koeficient determinace R^2 se vypočítá se pomocí rovnice (9). Uvedená rovnice byla převzata z literatury [12].

$$R^2 = \left(\frac{\sum_{i=1}^n (O_i - \bar{O}) \cdot (P_i - \bar{P})}{\sqrt{\sum_{i=1}^n (O_i - \bar{O})^2} \cdot \sqrt{\sum_{i=1}^n (P_i - \bar{P})^2}} \right)^2 \quad (9)$$


kde: O_i – naměřená hodnota průtoku v čase,

\bar{O} – průměr z naměřených hodnot průtoků,

P_i – předpovězená hodnota průtoku v čase,

\bar{P} – průměr z předpovězených hodnot průtoků.

Koeficient determinace R^2 nabývá hodnot $<0;1>$. Přesnost předpovědí lze zjistit podle toho, jaké hodnoty R^2 nabývá. Čím víc se R^2 blíží k 1, tím je úspěšnost předpovědi větší.



Obr. 5 Ukázka R^2 – měřený průtok a předpovězený průtok

R^2 je nezávislý na počtu x-ových prvků.

4.4.3. Nash-Sutcliffův koeficient

Nash-Sutcliffův koeficient E nabývá hodnot v rozsahu $(-\infty; 1>$. Vypočítá se pomocí rovnice (10), kde od jedné je odečítán podíl predikovaných a naměřených hodnot. Podíl sum rozdílů průtoků je upraven na hodnoty absolutních kvadratických odchylek. Z toho důvodu jsou v časové řadě větší hodnoty nadhodnocovány a malé hodnoty podhodnocovány. Při přesných předpovědích se Nash-Sutcliffův koeficient pohybuje v rozmezí hodnot blízko jedné. Pro výpočet Nash-Sutcliffova koeficientu E byl použit vzorec z literatury [12].

$$E = 1 - \frac{\sum_{t=1}^T (Q_0^t - Q_m^t)^2}{\sum_{t=1}^T (Q_0^t - \bar{Q}_0)^2} \quad (10)$$

kde: Q_0^t – naměřená hodnota průtoku v čase,

Q_m^t – předpovězená hodnota průtoku v čase,

\bar{Q}_0 – průměr z naměřených hodnot průtoků.

4.4.4. Index shody

Index shody d se pohybuje v rozmezí $<0;1>$. Pokud se jeho hodnota blíží 1, tak lze předpověď považovat jako poměrně přesnou. Byl navržen kvůli překonání necitlivosti určitých mezí Nash-Satcliffova koeficientu a koeficientu determinace. Posouzení je definováno jako poměr střední kvadratické chyby a potenciální chyby viz literatura [12]. Index shody se vypočítá se pomocí rovnice (11).

$$d = 1 - \frac{\sum_{i=1}^n (O_i - P_i)^2}{\sum_{i=1}^n (|P_i - \bar{O}| + |O_i - \bar{O}|)^2} \quad (11)$$

kde: O_i – naměřená hodnota průtoku v čase,

P_i – předpovězená hodnota průtoku v čase,

\bar{O} – průměr z naměřených hodnot průtoků.

5. PRAKTICKÁ APLIKACE

Diplomová práce byla rozdělena do dvou částí. V první části byl testován klasický model neuronových sítí a hybridní model pracující s řadou dodatečně generovaných umělých průtoků. Nejprve bylo nutné nalezení postupu pro použití neuronové sítě k předpovídání průměrných měsíčních průtoků v profilu vodního toku. Na obou modelech byla hledána optimální délka předpovědi, optimální počet vstupních měsíců, vhodné nastavení struktury sítě a volba vhodné tréninkové funkce. Po nalezení optimálního nastavení byly modely aplikovány pro předpovídání hodnot průměrných měsíčních průtoků v měrném profilu Dalečín. Předpovědi průtoků byly provedeny pomocí softwaru Matlab, který obsahuje Neural Network Toolbox.

V druhé části diplomové práce byla provedena praktická aplikace pro vodohospodářské účely, přesněji pro účely řízení vodohospodářské soustavy Vír I – Brno. Pro předpovídání průměrných měsíčních průtoků byl zvolen klasický model neuronových sítí. Model byl aplikován na data v měrném profilu Dalečín a v měrném profilu Skryje. Měrné profily se nacházejí na vodních tocích Svratka a Bobrůvka. Počet vstupních měsíců byl zvolen podle provedených testování modelu v první části diplomové práce. Délka předpovědi byla stanovena optimalizačním modelem, který byl použit v navazující diplomové práci pro řízení soustavy nádrží. Po konzultaci byla délka předpovědí určena na 1, 2, 4, 6, 10 a 12 měsíců vpřed. Historické průtokové řady byly poskytnuty Českým hydrometeorologickým ústavem. Pro měrný profil Dalečín byla k dispozici průtoková řada od roku 1950 do roku 2010 a pro měrný profil Skryje byla k dispozici průtoková řada od roku 1951 do roku 2010. Postup generování průměrných měsíčních průtoků bude blíže popisován na měrném profilu Dalečín.

5.1. Popis území

Měrné profily se nachází na vodním toku Svratka a na vodním toku Bobrůvka. Na soutoku řeky Bobrůvky s řekou Libochovkou vzniká řeka Loučka, která je pravobřežním přítokem do řeky Svratky. Svratka se nachází v povodí Moravy a je to významný levostranný přítok do řeky Dyje. Svratka zasahuje do okresů Žďár nad Sázavou v Kraji Vysočina a Brno-venkov, Brno-město a Břeclav v Jihomoravském kraji. Svratka pramení na úbočí Křivého javoru a Žákovy hory ve Žďárských vrších. Délka toku je 173,9 km a plocha povodí činí 7112,79 km². Řeka Svratka tvoří významný přítok do vodních nádrží Vír a Brno.

Bobrůvka protéká okresy Žďár nad Sázavou a Brno-venkov. Bobrůvka pramení 1 km západně od obce Rokytno a dále protéká obcí Nové Město na Moravě. Délka toku je 54,5 km a plocha povodí měří 236,9 km².



Obr. 6 Vodní tok Svratka [13]



Obr. 7 Povodí Svatky s označením měrných profilů [14]

5.1.1. Měrný profil Dalečín

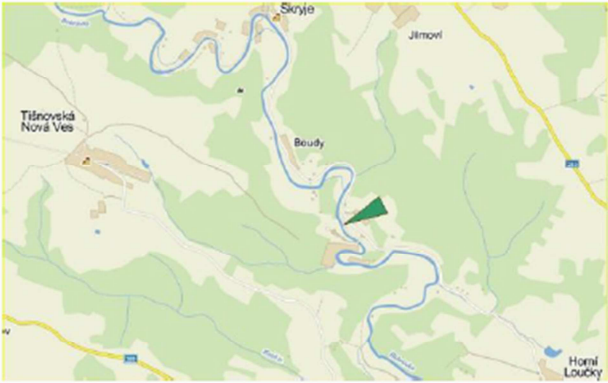
Měrný profil Dalečín se nachází na vodním toku Svratka, nad vodní nádrží Vír poblíž obce Dalečín. Bližší informace o průtocích viz evidenční list profilu (obr. 8).

Tok:	Svratka	Stanice:	Dalečín		
Kraj:	Vysočina	ORP:	Bystřice nad Pernštejnem	Obec:	Dalečín
Provozovatel stanice:		ČHMÚ Brno		Předpovědní profil ČHMÚ PP*	
Centrum automatického sběru dat:		RPP ČHMÚ Brno, VHD Povodí Moravy Brno			
Staničení:	125,70 [km]	Číslo hydrologického pořadí:	4-15-01-033		
Plocha povodí:	367,06 [km²]	Zeměpisné souřadnice:	161448 v.d. 493543 s.š.		
Nula vodočtu:	470,07 [m.n.m.]	Procento plochy povodí toku:	9,1		
Stupně povodňové aktivity:		[cm]	[m³.s⁻¹]	Platnost SPA pro úsek toku:	
bdělost	120		24,6	Jimramov - VD Vír	
pohotovost	150		42,5	Kritické místo:	
ohrožení	180		63,5		
Průměrný roční stav:	65 [cm]	N-leté průtoky:	Q ₁	Q ₅	Q ₁₀
Průměrný roční průtok:	3,44 [m³.s⁻¹]		Q ₅₀	Q ₁₀₀	
			39,2	73,9	91,6
			139	162	
Odesílatel zpráv:	Četnost hlášení SPA:	I.	1 x denně		
OÚ Dalečín		II.	4 x denně		
		III.	3hodinové hlášení		
Odesílatel podá zprávu:		Spojení na adresáta:		Příjemce dále vyrozumí:	
MěÚ Bystřice nad Pernštejnem		566590313, 566590321, 566590300, 725105421, 603582659		OÚ Strachujov, OÚ Unčín	
HZS Bystřice nad Pernštejnem		566552222			
VHD Povodí Moravy Brno		541 211 737, 541 637 250		Povodí Moravy - obsluha VD Vír	
RPP ČHMÚ Brno		541212485, 541421071, fax 541421018			
Nejvyšší zaznamenané vodní stavy:					
[cm]	V. - XI.	[cm]	XII. - IV.		
263	08.07.1997	194	25.03.1955		
232	17.07.1965	235	31.03.2006		
163	21.10.1960	190	31.03.1962		
156	07.06.1964	180	08.12.1974		
		179	28.12.1954		
Popis umístění profilu :					
silniční most pod továrnou KOH-I-NOR, levý břeh					
			Mapa v měřítku 1:50 000 :		

Obr. 8 Evidenční list hlášeného profilu č. 371[15]

5.1.2. Měrný profil Skryje

Měrný profil Skryje se nachází na vodním toku Bobrůvka, který se nachází poblíž obcí Skryje a Tišnovská Nová Ves. Bližší informace o průtocích viz evidenční list profilu (obr. 9).

Tok:	Loučka (Bobrůvka)		Stanice:	Skryje																																													
Kraj:	Jihomoravský kraj		ORP:	Tišnov	Obec:																																												
Provozovatel stanice:			ČHMÚ Brno																																														
Centrum automatického sběru dat:			RPP ČHMÚ Brno																																														
Staničení:	10.25	[km]	Číslo hydrologického pořadí:	4-15-01-096																																													
Plocha povodí:	222,01	[km ²]	Zeměpisné souřadnice:	161912 v.d. 492247 s.š.																																													
Nula vodočtu:	310,06	[m.n.m.]	Procento plochy povodí toku:	57,0																																													
Stupně povodňové aktivity:		[cm]	[m ³ .s ⁻¹]	Platnost SPA pro úsek toku:																																													
bdělost		90	12,0	Skryje - Dolní Loučky																																													
pohotovost		120	24,1	Kritické místo:																																													
ohrožení		150	37,2																																														
Průměrný roční stav:	40	[cm]	N-leté průtoky:	Q ₂	Q ₅																																												
Průměrný roční průtok:	1,47	[m ³ s ⁻¹]	[m ³ s ⁻¹]	17,0	35,1																																												
				Q ₁₀	Q ₅₀																																												
				44,3	68,4																																												
				Q ₁₀₀	80,0																																												
Odesílatel zpráv:	Četnost hlášení SPA:		I.	1x denně																																													
OÚ Horní Loučky			II.	4x denně																																													
			III.	3hodinové hlášení																																													
Odesílatel podá zprávu:		Spojení na adresáta:		Příjemce dále vyrozumí:																																													
<div> <div> <p>Nejvyšší zaznamenané vodní stavy:</p> <table border="1"> <tr> <td>[cm]</td> <td>V. - XI.</td> <td>[cm]</td> <td>XII. - IV.</td> </tr> <tr><td></td><td></td><td></td><td></td></tr> <tr><td></td><td></td><td></td><td></td></tr> <tr><td></td><td></td><td></td><td></td></tr> <tr><td></td><td></td><td></td><td></td></tr> <tr><td></td><td></td><td></td><td></td></tr> <tr><td></td><td></td><td></td><td></td></tr> <tr><td></td><td></td><td></td><td></td></tr> <tr><td></td><td></td><td></td><td></td></tr> <tr><td></td><td></td><td></td><td></td></tr> <tr><td></td><td></td><td></td><td></td></tr> </table> </div> <div> <p>Popis umístění profilu :</p> <p>ca 200 m nad silničním mostem (k bývalé továrněTylex), levý břeh</p> </div> </div> <div> <p>Mapa v měřítku 1:50 000 :</p>  </div>						[cm]	V. - XI.	[cm]	XII. - IV.																																								
[cm]	V. - XI.	[cm]	XII. - IV.																																														

Obr. 9 Evidenční list hlásného profilu č. 372a [16]

5.2. Popis a příprava dat

Data používaná pro předpovědi průměrných měsíčních průtoků byla rozdělena do dvou částí. První soubor dat byl použit pro první část diplomové práce. Používaná data byla převzata od Českého hydrometeorologického ústavu a téměř bez úprav byla aplikována při hledání nastavení neuronové sítě a při zjišťování přesnosti předpovědí pro klasický a hybridní model neuronových sítí. Data byla pouze rozdělena na vstupní (input) a validační (vzorová = sample) data. Pro měrný profil Dalečín bylo k dispozici 61 let historických naměřených průtoků. Jako validační data bylo použito posledních deset let z historické řady průtoků.

Druhý soubor dat byl použit pro předpovídání průtoků určených pro aplikaci do modelu, pomocí kterého se provádí optimalizace řízení vodohospodářské soustavy nádrží. Před samotným generováním průměrných měsíčních průtoků byly provedeny úpravy na základě definovaných cílů daných optimalizačním modelem. První z úprav byla rotace původních dat získaných od Českého hydrometeorologického ústavu do takového tvaru, který odpovídá hydrologickému roku. To znamená, že začíná prvním listopadovým dnem a končí posledním říjnovým dnem. Původní data byla řazena podle roku kalendářního od měsíce ledna do prosince.

Po provedené rotaci dat pro měrný profil Dalečín bylo nutné první rok (1950) vyřadit z průtokové řady. A to z důvodu nedostatku hodnot, které po provedených úpravách neutvářely celý rok. Rok 1950 tedy nelze použít jako vstupní data pro trénování sítě. Z roku 1950 jsou použity pouze hodnoty, které odpovídají měsícům listopad a prosinec, ty jsou označeny v tabulce (1) červeně. Černě označené hodnoty společně s červenými jsou při trénování neuronové sítě použity jako vstupní hodnoty. Z 60 let průtoků bylo použito pro validaci posledních sedm let z historické průtokové řady a k tomu byly přidány roky předpovídané v bakalářské práci [17]. V tab. 1 jsou to hodnoty průtoků, které jsou označeny hnědě a modře. Tyto hodnoty jsou v programu Matlab použity jako vzorová data. To znamená, že jsou to zároveň hodnoty průměrných měsíčních průtoků, které jsou pomocí modelu neuronových sítí předpovídány. Ve validačních letech jsou zahrnuty roky 1965, 1991 a 1993. Ty jsou v tabulce (1) označeny modře. Jsou to shodné roky, které byly předpovídány v bakalářské práci. Rok 38 (1991) byl definován jako málo vodný. Rok 40 (1993) byl popsán jako průměrně vodný a nakonec rok 12 (1965), který byl popsán jako extrémně vodný.

Pro měrný profil Skryje byla k dispozici řada historických naměřených průtoků o délce 59 let. Stejně jako u měrného profilu Dalečín byla validační data zvolena jako

posledních sedm let z historické řady a k tomu roky, které byly předpovídané stejně jako v bakalářské práci [17].

Tab. 1 Ukázka rotovaných hodnot průtoků pro měrný profil Dalečín

rok	rok	listopad	prosinec	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen
1951	1	3.410	3.071	2.937	5.983	5.098	3.045	6.706	2.553	1.665	1.592	0.495	0.576
1952	2	1.003	1.198	1.264	1.986	5.356	9.599	3.661	2.356	0.647	0.427	1.330	1.821
1953	3	3.984	2.165	3.395	6.874	5.471	2.660	2.001	3.129	2.963	1.252	0.753	0.817
1954	4	0.899	0.812	0.590	0.353	2.429	4.237	2.323	1.329	5.555	1.075	0.540	1.460
1955	5	1.197	7.278	4.554	3.940	7.776	9.616	2.968	1.311	2.150	2.041	1.272	1.029
1956	6	1.089	3.539	1.989	1.337	6.004	8.756	5.452	1.532	1.215	2.081	0.965	1.615
1957	7	5.019	3.368	3.856	5.330	6.736	5.844	1.509	0.700	2.070	1.245	1.300	1.175
1958	8	1.224	1.596	2.076	4.600	4.528	9.326	3.660	2.374	5.494	1.500	1.036	4.893
1959	9	2.543	3.382	4.380	3.736	3.577	1.765	2.487	2.135	3.568	2.425	0.930	0.913
1960	10	0.909	1.780	2.548	5.159	8.628	3.351	2.312	2.820	2.761	4.403	2.783	6.174
*	*	*	*	*	*	*	*	*	*	*	*	*	*
*	*	*	*	*	*	*	*	*	*	*	*	*	*
1999	46	7.161	4.586	3.194	5.135	13.854	3.899	1.780	3.434	3.397	1.085	1.157	1.193
2000	47	1.264	1.418	2.171	10.251	15.187	5.605	1.398	1.040	1.719	0.978	0.778	1.059
2001	48	1.089	1.114	1.541	2.946	4.894	3.889	2.480	1.826	3.979	1.900	3.911	1.974
2002	49	2.053	1.882	5.984	10.855	4.828	2.749	2.068	1.231	1.017	5.132	2.322	2.158
2003	50	3.875	3.652	6.494	2.535	3.708	2.279	5.019	1.347	1.072	0.588	0.981	1.398
2004	1	1.090	2.074	3.354	10.280	6.848	4.696	1.847	1.655	1.516	0.796	1.046	1.239
2005	2	3.938	2.457	3.931	3.801	13.033	5.446	2.068	1.361	3.783	1.746	1.381	0.904
2006	3	0.854	1.637	1.400	1.660	10.100	17.400	6.540	2.950	1.550	5.360	1.580	1.510
2007	4	3.710	1.990	4.020	6.870	8.350	2.880	1.570	1.260	0.936	0.507	2.930	2.050
2008	5	5.630	6.150	5.410	3.760	7.480	3.830	2.230	1.550	1.610	1.190	1.090	1.280
2009	6	1.530	2.400	1.740	2.780	14.800	5.820	1.730	2.670	5.300	2.250	1.330	2.410
2010	7	2.520	3.510	3.350	2.610	10.300	6.980	5.690	6.420	2.010	3.700	5.990	2.850
1965	8	3.471	3.090	2.283	1.976	12.422	10.244	7.153	8.406	6.172	2.346	2.089	1.800
1991	9	1.269	1.216	2.145	0.874	1.840	1.788	3.472	1.879	1.572	2.635	0.697	0.886
1993	10	1.001	1.456	2.834	1.550	6.541	5.398	1.744	1.290	0.980	0.549	1.338	1.155

Data v tabulce (1) jsou již rotací upravená data do požadovaného tvaru. Takto upravená data pomocí rotace již lze použít pro následnou normalizaci a načtení do programu Matlab. Z důvodu přehlednosti jsou hodnoty průtoků v tabulce (1) zkráceny o roky 1961 až 1998.

5.2.1. Normalizace dat

Po provedené rotaci dat je nutné provést normalizaci dat z důvodu zrychlení a zpřesnění natrénování neuronové sítě. Postup normalizování dat byl popsán v kapitole 4.1.1., kdy za pomoci rovnice (1) byly hodnoty průtoků upraveny tak, aby se normalizované hodnoty pohybovaly v intervalu $<-1,1>$. Rovnice (1) byla použita pro výpočet sloupcovým způsobem určování maximálních a minimálních průtoků. Ukázka normalizovaných hodnot je uvedena v následující tabulce (2), kde z důvodu přehlednosti jsou roky 1961 až 1998 odebrány.

Tab. 2 Ukázka normalizovaných hodnot průtoků pro měrný profil Dalečín

rok	rok	listopad	prosinec	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen
1951	1	-0.166	-0.643	-0.493	-0.116	-0.582	-0.781	0.265	-0.436	-0.913	-0.560	-1.000	-0.987
1952	2	-0.915	-0.917	-0.802	-0.743	-0.541	-0.056	-0.437	-0.496	-1.000	-0.993	-0.686	-0.545
1953	3	0.012	-0.776	-0.408	0.024	-0.523	-0.823	-0.819	-0.261	-0.801	-0.687	-0.903	-0.901
1954	4	-0.947	-0.974	-0.926	-0.999	-1.000	-0.649	-0.745	-0.809	-0.579	-0.753	-0.983	-0.673
1955	5	-0.854	-0.028	-0.194	-0.436	-0.162	-0.054	-0.596	-0.814	-0.871	-0.394	-0.708	-0.826
1956	6	-0.888	-0.575	-0.668	-0.845	-0.440	-0.149	-0.024	-0.747	-0.951	-0.379	-0.823	-0.618
1957	7	0.334	-0.600	-0.323	-0.218	-0.325	-0.471	-0.932	-1.000	-0.878	-0.689	-0.697	-0.774
1958	8	-0.846	-0.859	-0.652	-0.333	-0.671	-0.086	-0.437	-0.491	-0.584	-0.595	-0.797	0.545
1959	9	-0.436	-0.598	-0.226	-0.468	-0.820	-0.922	-0.707	-0.563	-0.749	-0.251	-0.836	-0.867
1960	10	-0.944	-0.832	-0.564	-0.245	-0.028	-0.747	-0.747	-0.355	-0.819	0.484	-0.139	1.000
*	*	*	*	*	*	*	*	*	*	*	*	*	*
*	*	*	*	*	*	*	*	*	*	*	*	*	*
1999	46	1.000	-0.421	-0.445	-0.249	0.791	-0.686	-0.870	-0.168	-0.764	-0.749	-0.751	-0.768
2000	47	-0.834	-0.885	-0.634	0.554	1.000	-0.497	-0.958	-0.897	-0.908	-0.789	-0.894	-0.815
2001	48	-0.888	-0.929	-0.750	-0.592	-0.614	-0.687	-0.708	-0.657	-0.714	-0.446	0.285	-0.490
2002	49	-0.588	-0.817	0.070	0.649	-0.624	-0.813	-0.803	-0.838	-0.968	0.755	-0.313	-0.425
2003	50	-0.022	-0.558	0.164	-0.657	-0.799	-0.865	-0.124	-0.803	-0.964	-0.933	-0.817	-0.695
2004	51	-0.901	-0.652	-0.025	1.000	-0.227	-0.627	-0.901	-0.889	-0.778	-0.881	-0.868	-0.641
2005	52	0.291	-0.497	0.262	-0.378	0.727	-0.531	-0.822	-0.972	0.087	-0.489	-0.742	-0.982
2006	53	-1.000	-0.829	-1.000	-0.833	0.275	1.000	0.780	-0.527	-0.765	1.000	-0.666	-0.365
2007	54	0.196	-0.686	0.307	0.275	0.005	-0.860	-1.000	-1.000	-1.000	-1.000	-0.156	0.185
2008	55	1.000	1.000	1.000	-0.386	-0.130	-0.738	-0.764	-0.919	-0.743	-0.719	-0.852	-0.599
2009	56	-0.717	-0.520	-0.830	-0.595	1.000	-0.483	-0.943	-0.605	0.667	-0.282	-0.761	0.552
2010	57	-0.302	-0.070	-0.027	-0.631	0.306	-0.335	0.476	0.444	-0.590	0.316	1.000	1.000
1965	12	0.096	-0.240	-0.560	-0.766	0.633	0.083	1.000	1.000	1.000	-0.242	-0.474	-0.069
1991	38	-0.826	-1.000	-0.628	-1.000	-1.000	-1.000	-0.319	-0.827	-0.757	-0.123	-1.000	-1.000
1993	40	-0.938	-0.903	-0.285	-0.856	-0.275	-0.538	-0.938	-0.992	-0.983	-0.983	-0.758	-0.726
min		0.729	0.632	0.190	0.349	2.429	1.061	1.214	0.700	0.647	0.409	0.495	0.538
max		7.161	14.301	11.018	13.092	15.187	19.143	9.900	7.272	23.967	5.792	5.812	6.174
min		0.854	1.216	1.400	0.874	1.840	1.788	1.570	1.260	0.936	0.507	0.697	0.886
max		5.630	6.150	5.410	10.280	14.800	17.400	7.153	8.406	6.172	5.360	5.990	2.850

5.2.2. Příprava dat k načtení do Neural Network Toolbox

Již normalizovaná data byla dále rozdělena podle použití pro trénování neuronové sítě a simulaci výstupních hodnot. Rozdělení dat bylo provedeno takovým způsobem, který software Matlab vyžaduje, přesněji Neural Network Toolbox. Načítání dat do Matlabu bylo provedeno přímo ze souboru Excel pomocí funkce „ddeinit“, která je součástí programu Matlab. Již načtená data z Excelu byla dále roztržena pomocí funkce „ddereq“ do třech skupin. První skupina obsahuje vstupní (input) data (obr. 10), druhá skupina obsahuje cílová (target) data (obr. 11) a třetí skupina obsahuje vzorová (sample) data (obr. 12). Vstupní a cílová data slouží pro natrénování neuronové sítě a vzorová data odpovídají hodnotám zvoleným pro validaci a jsou dále použita při simulaci výstupních (output) dat. Vstupní, cílová i vzorová data jsou načítána vždy ve tvaru dvanácti matic hodnot. Je to dáno metodou předpovídání, kdy při každé předpovědi jsou vstupní i cílová data rotována o jeden měsíc vpřed, dokud není provedena rotace všech dvanácti měsíců.

```
%% Načtení souboru se vstupními daty 50let
spojeni1=ddeinit('excel','data k načtení 50let (-1,1).xlsx');%otevření souboru data.xlsx
%%vstupní data INPUT
input01=ddereq(spojeni1,'r1c1:r9c50');%r - row (radek) c - colum (sloupec)
input02=ddereq(spojeni1,'r2c1:r10c50');
input03=ddereq(spojeni1,'r3c1:r11c50');
input04=ddereq(spojeni1,'r4c1:r12c50');
input05=ddereq(spojeni1,'r5c1:r13c50');
input06=ddereq(spojeni1,'r6c1:r14c50');
input07=ddereq(spojeni1,'r7c1:r15c50');
input08=ddereq(spojeni1,'r8c1:r16c50');
input09=ddereq(spojeni1,'r9c1:r17c50');
input10=ddereq(spojeni1,'r10c1:r18c50');
input11=ddereq(spojeni1,'r11c1:r19c50');
input12=ddereq(spojeni1,'r12c1:r20c50');
```

Obr. 10 Ukázka načítání vstupních dat v programu Matlab


```

%%vstupni data TARGET
target01=ddereq(spojeni1,'r10c1:r21c50');
target02=ddereq(spojeni1,'r11c1:r22c50');
target03=ddereq(spojeni1,'r12c1:r23c50');
target04=ddereq(spojeni1,'r13c1:r24c50');
target05=ddereq(spojeni1,'r14c1:r25c50');
target06=ddereq(spojeni1,'r15c1:r26c50');
target07=ddereq(spojeni1,'r16c1:r27c50');
target08=ddereq(spojeni1,'r17c1:r28c50');
target09=ddereq(spojeni1,'r18c1:r29c50');
target10=ddereq(spojeni1,'r19c1:r30c50');
target11=ddereq(spojeni1,'r20c1:r31c50');
target12=ddereq(spojeni1,'r21c1:r32c50');

```

Obr. 11 Ukázka načítání cílových dat v programu Matlab

```

%% Nacteni souboru se vstupnimi daty 10let
spojeni2=ddeinit('excel','data k načtení 10let (-1,1).xlsx');
%%vstupni data SAMPLE
sample01=ddereq(spojeni2,'r1c1:r9c10');
sample02=ddereq(spojeni2,'r2c1:r10c10');
sample03=ddereq(spojeni2,'r3c1:r11c10');
sample04=ddereq(spojeni2,'r4c1:r12c10');
sample05=ddereq(spojeni2,'r5c1:r13c10');
sample06=ddereq(spojeni2,'r6c1:r14c10');
sample07=ddereq(spojeni2,'r7c1:r15c10');
sample08=ddereq(spojeni2,'r8c1:r16c10');
sample09=ddereq(spojeni2,'r9c1:r17c10');
sample10=ddereq(spojeni2,'r10c1:r18c10');
sample11=ddereq(spojeni2,'r11c1:r19c10');
sample12=ddereq(spojeni2,'r12c1:r20c10');

```

Obr. 12 Ukázka načítání vzorových dat v programu Matlab

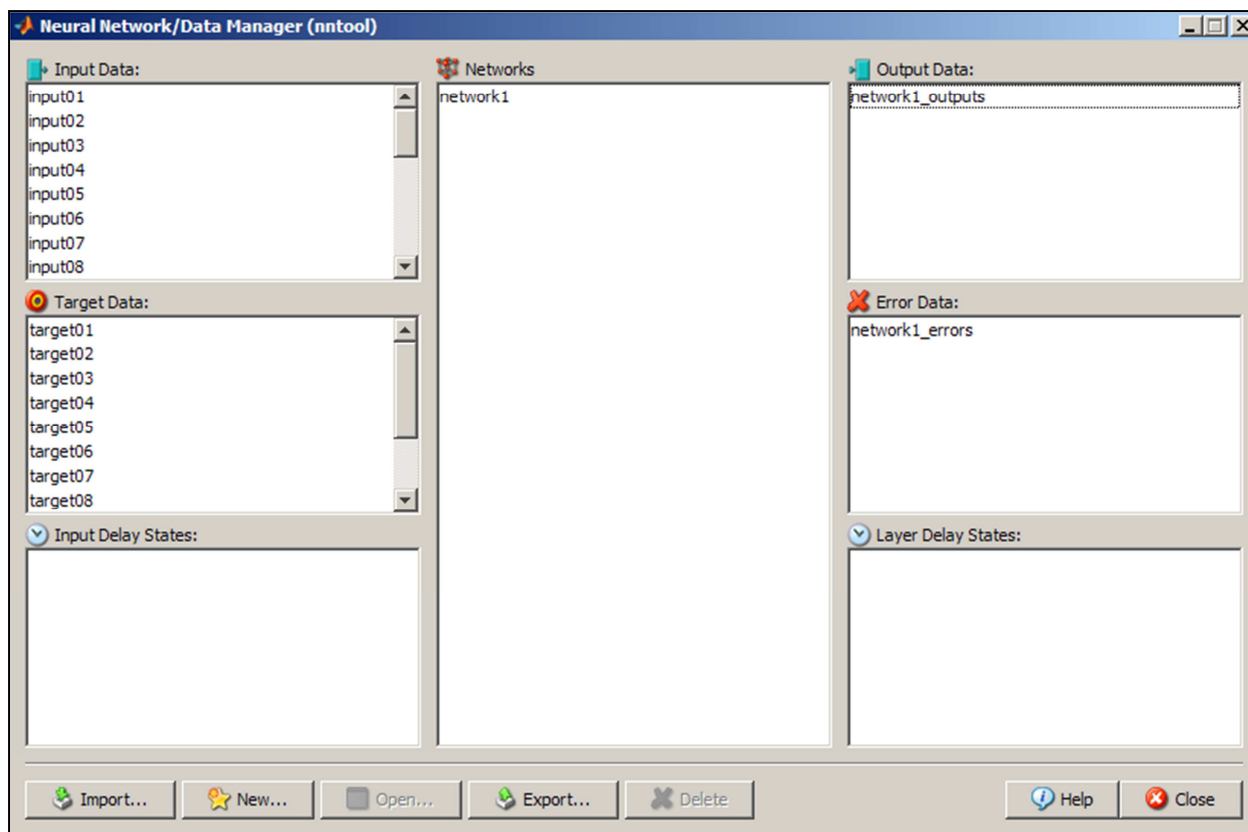
Takto načtená data jsou uchovávána v Matlab Workspace (obr. 13), odkud se dále používají při vytváření neuronové sítě pomocí Neural Network/Data Manager, který se spouští funkcí „nntool“ (obr. 14).

Workspace			
Name ▲	Value	Min	Max
input01	<9x50 double>	-1	1
input02	<9x50 double>	-1	1
input03	<9x50 double>	-1	1
input04	<9x50 double>	-1	1
input05	<9x50 double>	-1	1
input06	<9x50 double>	-1	1
input07	<9x50 double>	-1	1
input08	<9x50 double>	-1	1
input09	<9x50 double>	-1	1
input10	<9x50 double>	-1	1
input11	<9x50 double>	-1	1
input12	<9x50 double>	-1	1
sample01	<9x10 double>	-1	1
sample02	<9x10 double>	-1	1
sample03	<9x10 double>	-1	1
sample04	<9x10 double>	-1	1
sample05	<9x10 double>	-1	1
sample06	<9x10 double>	-1	1
sample07	<9x10 double>	-1	1
sample08	<9x10 double>	-1	1
sample09	<9x10 double>	-1	1
sample10	<9x10 double>	-1	1

Obr. 13 Ukázka načtených dat uložených v Matlab Workspace

5.3. Práce s Neural Network Toolbox

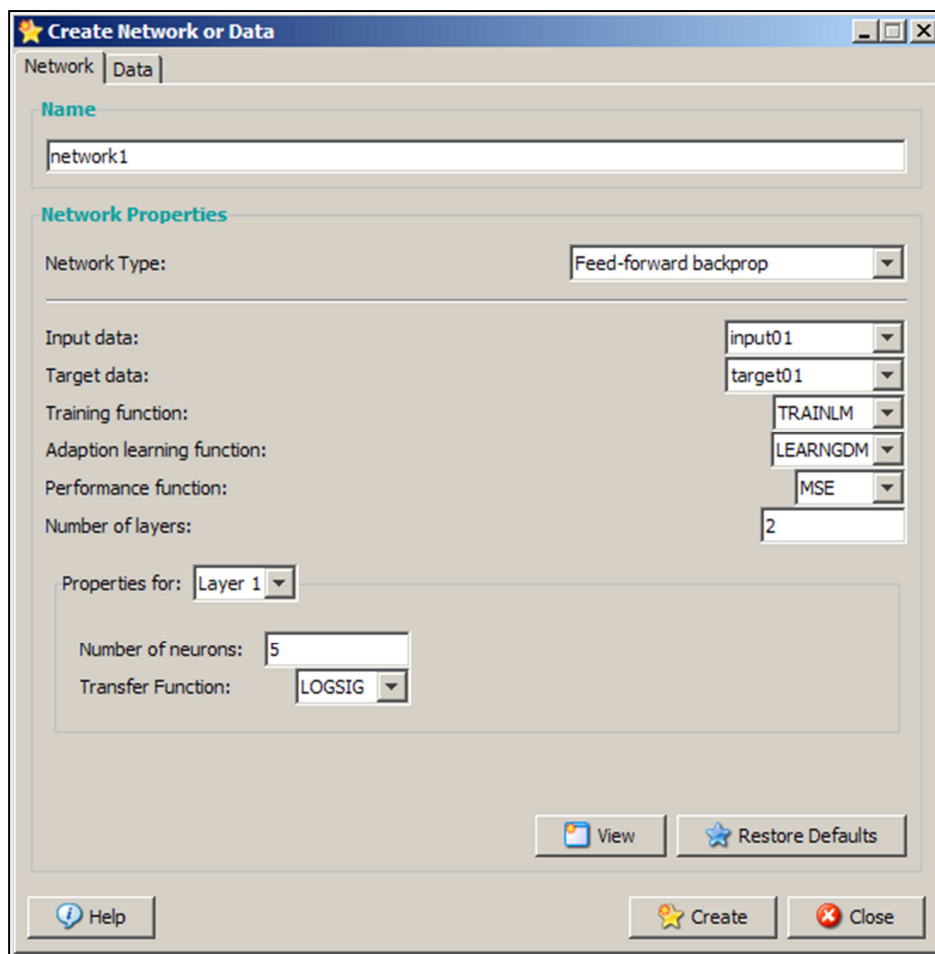
Práce s Neural Network Toolbox, který je obsažen v programu Matlab, je prováděna pomocí okna Neural Network/Data Manager (obr. 14). Nejprve je nutné z Matlab Workspace do Neural Network/Data Manager importovat vstupní (input), vzorová (sample) a cílová (target) data do příslušných oken. Teprve potom je možné v okně "Networks" vytvořit novou síť, které se přiřazují již načtená vstupní a cílová data. V okně Output data jsou shromažďována výstupní (output) data, která lze získat po natrénování sítě a po provedené simulaci hodnot.



Obr. 14 Ukázka importovaných dat do Neural Network/Data Manager v programu Matlab

5.3.1. Nastavení neuronové sítě

V okně "Networks" je seznam neuronových sítí, které byly vytvořeny. Při vytváření nové sítě se volí typ sítě, vstupní a cílová data, typ tréninkové funkce, topologie sítě a typ aktivační (přenosové) funkce.



Obr. 15 Ukázka nastavení neuronové sítě v programu Matlab

Konečné nastavení neuronové sítě bylo získáno postupnými úpravami topologie sítě, zkoušením úprav tréninkových prvků a koeficientů a volbou vhodných funkcí pro trénování.

Struktura sítě byla nastavena jako dvouvrstvá. Obsahovala jednu skrytou a jednu výstupní vrstvu, kdy počet neuronů ve skryté vrstvě byl nastaven na deset a počet neuronů ve výstupní vrstvě byl nastaven na jeden. Později byl počet neuronů ve skryté vrstvě, z důvodu zlepšení přesnosti trénování sítě, snížen na pět. Při volbě aktivační (přenosové) funkce bylo voleno z funkcí LOGSIG (logistická sigmoidální), PURELIN (lineární) a TANSIG (tangenciální sigmoidální). Ve skryté vrstvě byla nastavena funkce LOGSIG a ve výstupní vrstvě byla nastavena funkce PURELIN, protože lineární funkce ve výstupní vrstvě umožňuje větší výstupní rozsah než funkce sigmoidální.

5.3.2. Typ sítě

Typ neuronové sítě byl zvolen jako dopředný, používající způsob učení se schopností zpětného šíření (feed-forward backpropagation). Je to metodika dopředného a zároveň

zpětného prohledávání optimálních velikostí synoptických vah takovým způsobem, aby se odchylka od správného řešení snížila co možná nejvíce a v co nejkratším čase.

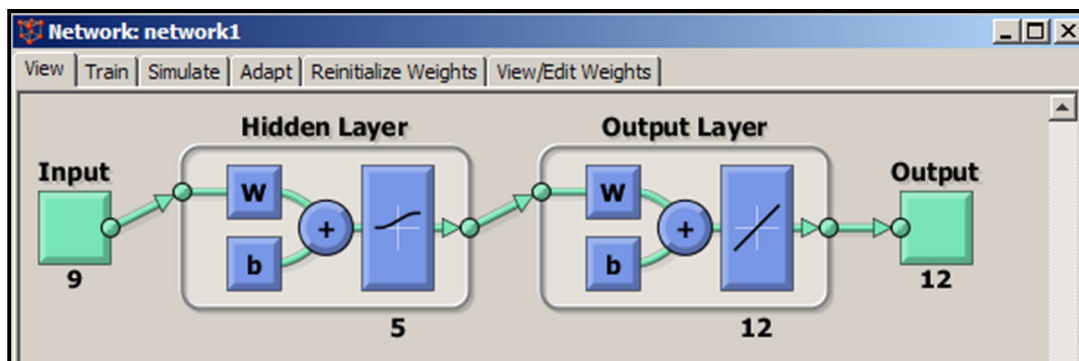
5.3.3. Tréninkové funkce

Pro trénování sítě byla volena funkce nabízená z možných funkcí, které obsahuje Neural Network Toolbox. Tréninkové funkce, které lze nastavit v Neural Network/Data Manager jsou: `traingd` (základní gradientní algoritmus), `traingda` (gradientní algoritmus s adaptivní rychlostí učení), `traingdm` (momentový algoritmus), `traingdx` (momentový algoritmus s adaptivní rychlostí učení) a `trainlm`. Při trénování byly testovány funkce `traingdm`, `traingdx` a `trainlm`. Nejlepší výsledky a nejrychlejší natrénování sítě vykazovala tréninková funkce `trainlm`. Funkce `trainlm` upravuje hodnoty synoptických vah pomocí Levenberg-Marquardt optimalizace. Po otestování tréninkových funkcí byla pro všechny předpovědi zvolena funkce `trainlm`.

Z validačních funkcí bylo na výběr z MSE (mean squared normalized error – průměr kvadratických normalizovaných chyb), SSE (sum squared error – suma kvadratických chyb) a MSEREG (mean squared error and the mean squared weight and bias values – průměr kvadratických chyb a průměr kvadratické hodnoty váhy). Pro trénování sítí byla zvolena funkce MSE, která je programem Matlab nastavena defaultně.

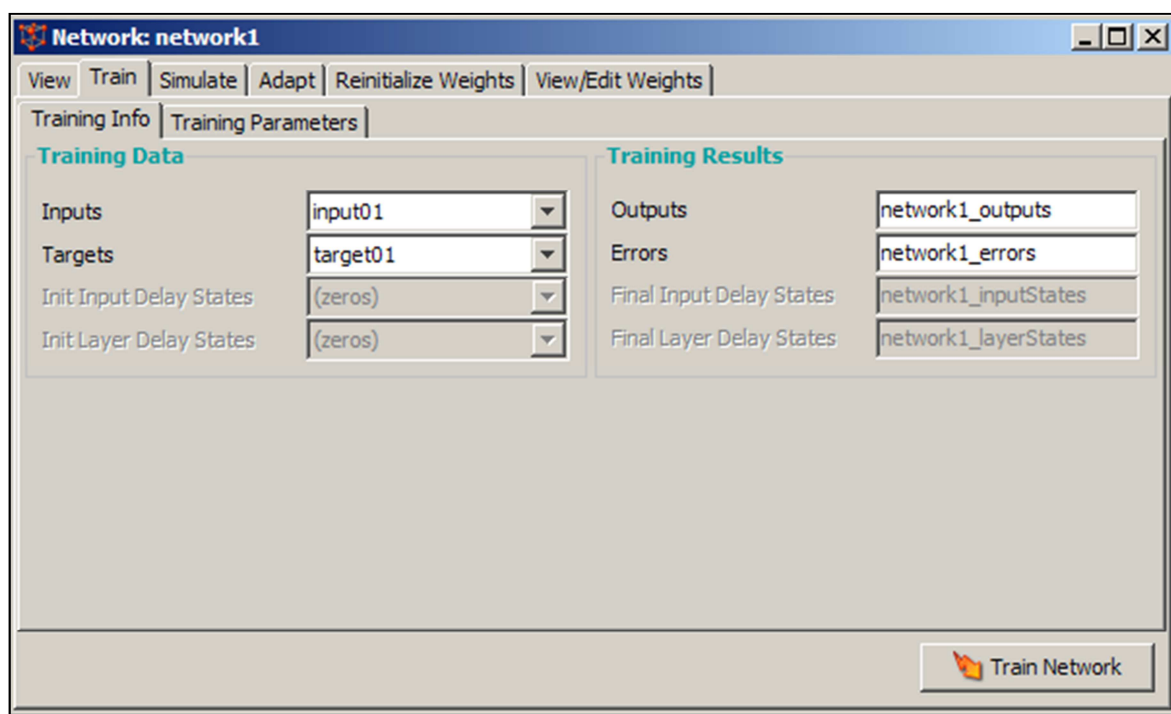
5.3.4. Trénování neuronové sítě a simulace hodnot

Po nastavení neuronové sítě následuje její natrénování. V prvním kroku Matlab nabízí ukázkou nastavené sítě (obr. 16).



Obr. 16 Ukázka nastavené neuronové sítě v programu Matlab

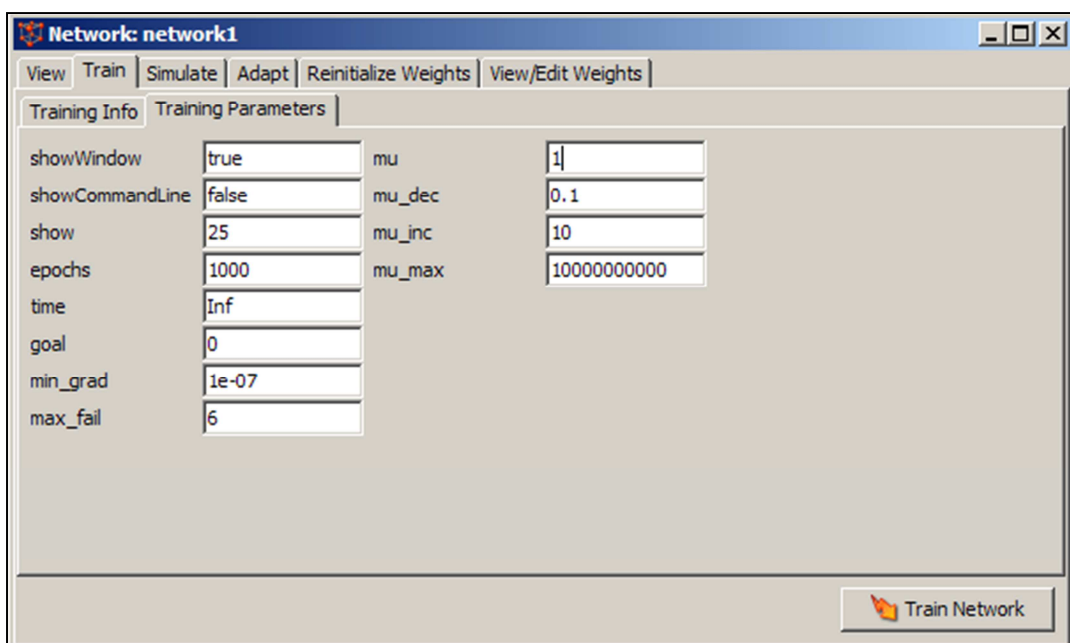
V dalším kroku se nastavují vstupní (input) a cílová (target) data, která byla importována do Neural Network/Data Manager (obr. 17).



Obr. 17 Ukázka nastavení dat pro trénování neuronové sítě v programu Matlab

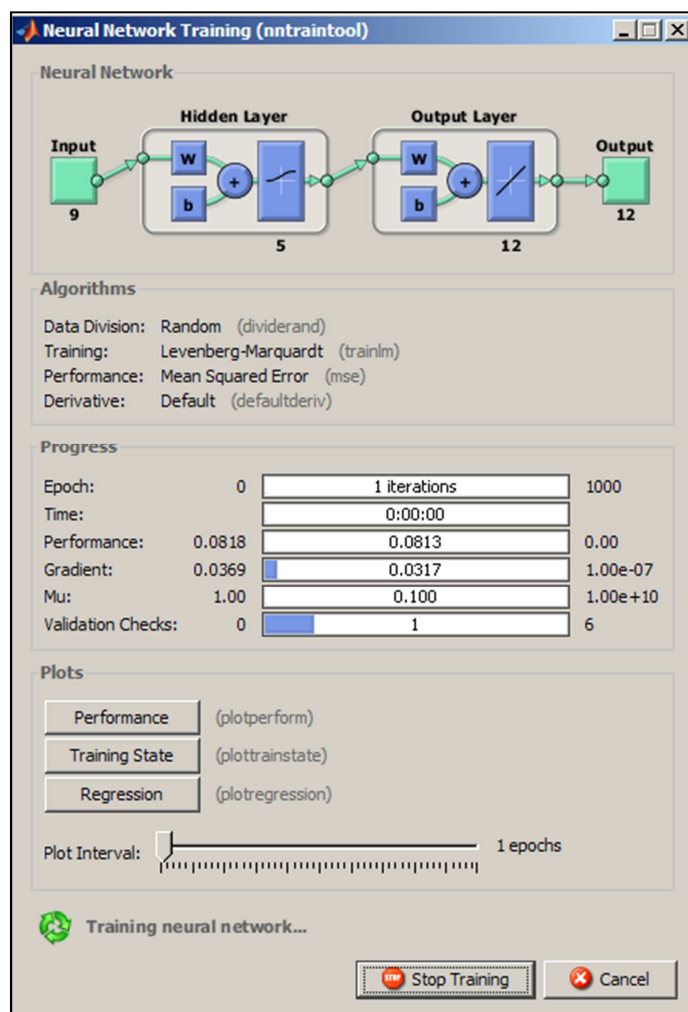
Dalším neméně důležitým krokem bylo nastavení tréninkových parametrů. Základním parametrem bylo nastavení počtu epoch, po kterých je trénování sítě ukončeno. Počet tréninkových epoch byl testován o velikostech 100, 500 a 1000 epoch. Počet zvolených epoch nakonec nebyl nutný měnit, protože takto zvolená neuronová síť ukončila trénování většinou dříve, než dosáhla určitý počet epoch. Trénování neuronové sítě bylo většinou ukončeno po získání šesti validačních ověření. Počet epoch byl tedy nakonec ponechán na 1000, jak Matlab nabízí defaultně.

Další velikosti koeficientů, důležitých při trénování, byly zkoušeny experimentálně, kdy například bylo zvoleno několik hodnot koeficientu μ , který je nutno nastavit před samotným trénováním sítě (obr. 18). Hodnoty koeficientu μ byly testovány o velikostech 0,001 (defaultně); 1; 0,1; 0,01 a 0,0001. Se zvolenými hodnotami parametru μ bylo opakovaně vyzkoušeno natrénovat síť a byly porovnávány odchylky při simulaci výstupních hodnot. Podle toho, která simulace vykazovala nejmenší odchylku, byl odpovídající parametr μ zvolen při všech následujících trénováních. Nejlepších průměrných hodnot R^2 bylo dosaženo s hodnotami μ 1 a 0,001. Pro následující trénování neuronových sítí byla zvolena hodnota koeficientu $\mu=1$.




Obr. 18 Ukázka nastavení tréninkových parametrů v programu Matlab

Průběh samotného natrénování sítě lze vidět na obr. 19.



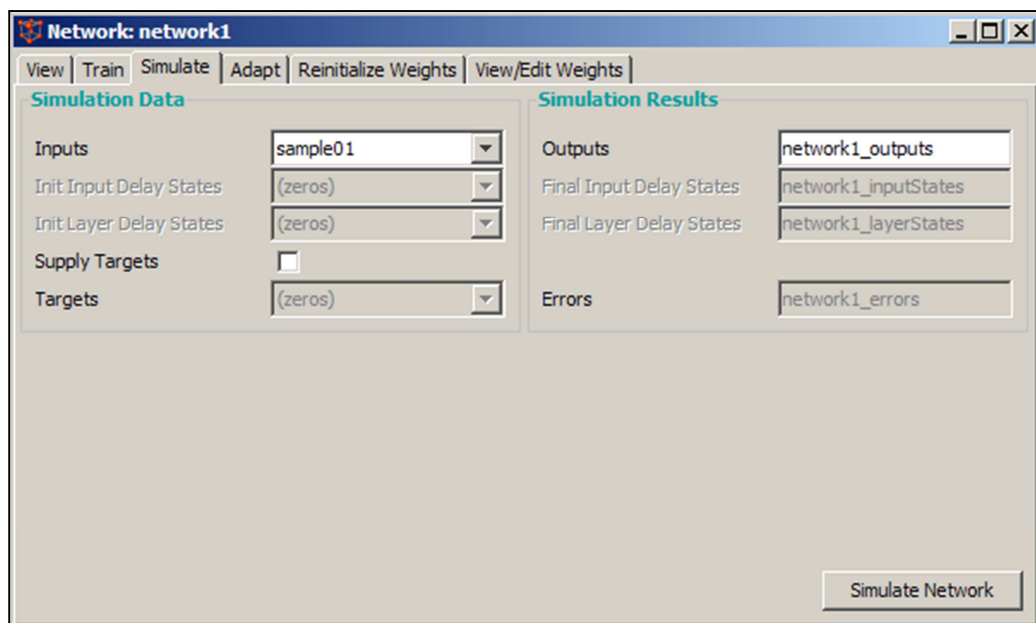
Obr. 19 Ukázka průběhu trénování neuronové sítě v programu Matlab

Po úspěšném natrénování lze zobrazit graf „Performance“ (obr. 20) a podívat se na průběh trénování, kde na svislé ose je znázorněn průměr kvadratických normalizovaných chyb MSE a na vodorovné ose počet tréninkových epoch. V kroužku je označena epocha, kde byla dosažena nejlepší validační hodnota.




Obr. 20 Graf průběhu trénování neuronové sítě v programu Matlab

Po natrénování neuronové sítě, lze spustit simulaci (predikci) výstupních (output) dat. K nasimulování výstupů jsou použita vzorová (sample) data (obr. 21).



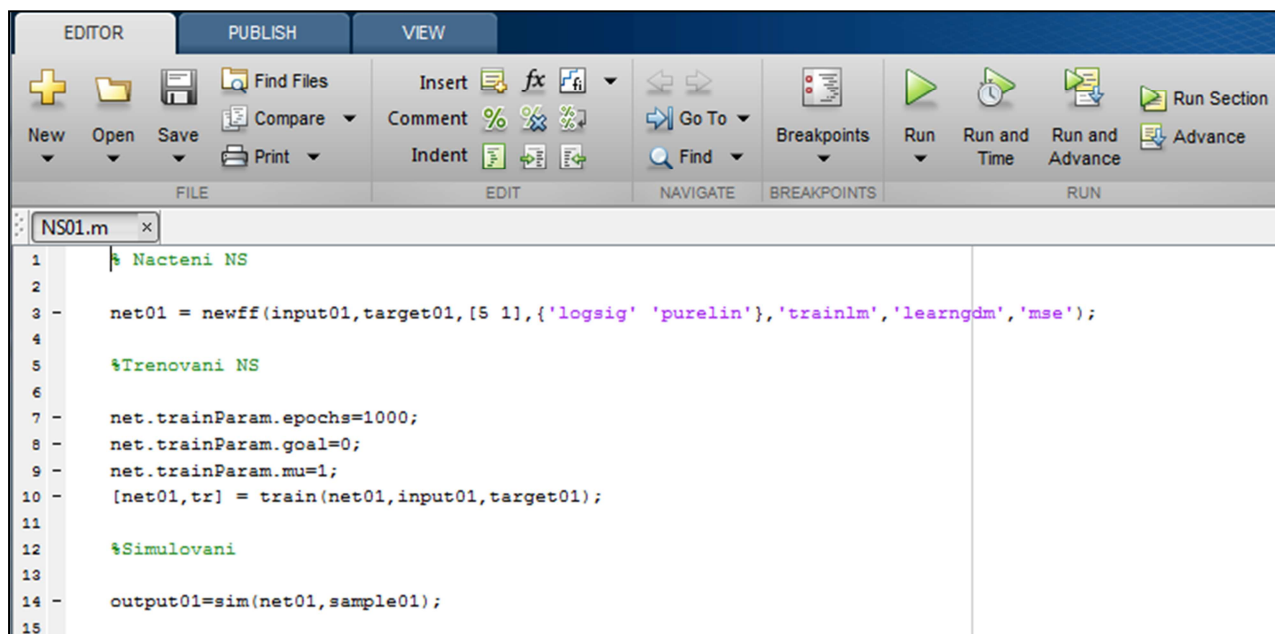
Obr. 21 Ukázka simulace výstupů v programu Matlab

Po nasimulování neuronové sítě byl proveden export výstupních (output) dat do Matlab Workspace (obr. 22), odkud s nimi lze dále pracovat při zpětné normalizaci na hodnoty průtoků a při vyhodnocování úspěšnosti předpovědi.



Obr. 22 Ukázka exportu dat do Matlab Workspace

Průběh trénování neuronové sítě a simulace dat lze v Matlabu podstatně zjednodušit použitím skriptu (obr. 23). Skript byl napsán pomocí programovacího jazyka, který program Matlab používá. Jednotlivé postupy uvedené v předchozím textu byly shrnuty pomocí seznamu příkazů, které Matlab postupně spouští.



Obr. 23 Ukázka trénování a simulace skriptem v programu Matlab

5.4. Nalezení optimální předpovědi průměrných měsíčních průtoků

V první části diplomové práce byl jeden z úkolů nalézt nejlepší délku předpovědi a s ní související počet vstupních měsíců a následně i předpovězených měsíců. Jedná se o nalezení optimální délky předpovědi vzad, přesněji o nalezení vhodného počtu vstupních měsíců pro předpověď. Po nalezení vhodného počtu vstupních měsíců je neméně důležité nalézt také optimální délku předpovědi, jak bylo zmíněno výše v kapitole 4.2.

Hledání optimální délky předpovědi a vhodného počtu vstupních měsíců bylo provedeno pro klasický i hybridní model neuronových sítí. Optimální počty měsíců byly zjišťovány vyhodnocením pomocí R^2 . Nash-Sutcliffův koeficient a Index shody byly zpracovány, ale nejlepší vyhodnocení nakonec poskytoval R^2 . Pro stanovení vhodného počtu vstupních měsíců byla použita suma R^2 pro jednotlivé počty zvolených měsíců.

Pro stanovení optimální délky předpovědi byly použity průměrné hodnoty sum koeficientů determinace v daných rotacích pro určitý počet předpovídaných měsíců, kdy pro každý počet předpovídaných měsíců bylo vytvořeno dvanáct rotací.

Výpočet R^2 byl prováděn pomocí postupu popsaného v kapitole 4.4.2. a grafickým způsobem pomocí vložení spojnice trendu a zobrazení koeficientu spolehlivosti do grafu v programu Excel.


5.4.1. Stanovení optimální předpovědi vzad pro klasický model neuronových sítí

Výpis sum koeficientů determinace stanovených výpočtem při určení vhodného počtu vstupních měsíců pro jednotlivé rotované měsíce je uveden v tab. 3, kde jednotlivé sloupce udávají dílčí hodnoty koeficientů determinace pro dané rotace, odpovídající měsícům, jdoucích v roce po sobě. Řádky v tabulce (3) odpovídají počtům vstupních měsíců, nebo také délce předpovědi vzad.


Tab. 3 Výpočet sum koeficientů determinace při stanovení optimální předpovědi vzad

	1 měsíc	2 měsíce	3 měsíce	4 měsíce	5 měsíců	6 měsíců
rotace	koeficient determinace					
1	0.264	0.038	0.204	0.021	0.179	0.032
2	0.001	0.06	0.217	0.098	0.218	0.414
3	0.049	0.334	0.513	0.783	0.252	0.369
4	0.602	0.127	0.014	0.037	0.298	0.064
5	0.354	0.258	0.156	0.006	0.197	0.033
6	0.000	0	0.077	0.091	0.002	0.377
7	0.031	0.048	0.196	0.006	0.125	0.003
8	0.276	0.524	0.356	0.418	0.035	0.217
9	0.059	0.019	0.027	0.149	0.021	0.003
10	0.460	0.16	0.011	0.033	0.037	0.056
11	0.409	0	0.68	0.672	0.003	0.095
12	0.018	0.247	0.107	0.041	0.214	0.211
průměr	0.210	0.151	0.213	0.196	0.127	0.167
suma	2.523	1.815	2.558	2.355	1.581	1.874
	7 měsíců	8 měsíců	9 měsíců	10 měsíců	11 měsíců	12 měsíců
rotace	koeficient determinace					
1	0.509	0.14	0.331	0.06	0.002	0.011
2	0.007	0.23	0.006	0.148	0.089	0.005
3	0.053	0.145	0.308	0.071	0.314	0.291
4	0.004	0.227	0.771	0.054	0.025	0.135
5	0.028	0.049	0.071	0.045	0.047	0.002
6	0	0.106	0.031	0.203	0.46	0.168
7	0.16	0.365	0.241	0.444	0.022	0
8	0.018	0.008	0.408	0.123	0.273	0.18
9	0.11	0.184	0.579	0.003	0.023	0.005
10	0.29	0.58	0.342	0	0.038	0.133
11	0.223	0.143	0.242	0.159	0.419	0.069
12	0.153	0.178	0.121	0.371	0.613	0.419
průměr	0.130	0.196	0.288	0.140	0.194	0.118
suma	1.555	2.355	3.451	1.681	2.325	1.418


R^2 stanovené pomocí grafů v Excelu jsou na obr. 24 až 35. Pro grafy platí závislost naměřených průtoků, které jsou na ose X, na předpovězených průtocích na ose Y. Soubor grafů stanovujících koeficienty determinace je prezentován pro devět vstupních měsíců.




Obr. 24 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 1. rotaci




Obr. 25 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 2. rotaci




Obr. 26 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 3. rotaci




Obr. 27 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 4. rotaci




Obr. 28 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 5. rotaci




Obr. 29 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 6. rotaci




Obr. 30 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 7. rotaci




Obr. 31 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 8. rotaci




Obr. 32 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 9. rotaci



Obr. 33 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 10. rotaci



Obr. 34 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 11. rotaci



Obr. 35 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 12. rotaci

Sumy koeficientů determinace (tab. 4) jsou porovnány a obarveny podle velikosti, kde červeně označené hodnoty jsou nejvyšší a modře označené hodnoty nejnižší. Nejlepších výsledků bylo dosaženo při předpovědi s devíti vstupními měsíci.

Tab. 4 Porovnání sum koeficientů determinace při stanovení vhodného počtu vstupních měsíců vzad

počet vstupních měsíců	koeficient determinace
1	2.52
2	1.82
3	2.56
4	2.36
5	1.58
6	1.87
7	1.56
8	2.36
9	3.45
10	1.68
11	2.33
12	1.42
MAX	3.45
PRŮMĚR	2.12

Po nalezení vhodného počtu vstupních měsíců následovalo hledání optimální délky předpovědi, kdy počet vstupních měsíců byl nadále nastaven na devět.

5.4.2. Stanovení optimální předpovědi vpřed pro klasický model neuronových sítí

Stanovení optimálního počtu předpovídaných měsíců vpřed bylo provedeno pomocí sum koeficientů determinace. Jednotlivé hodnoty sum koeficientů determinace uvedených v tabulce (5) odpovídají součtu koeficientů determinace stanovovaných při předpovědích v daných rotacích pro zvolenou délku předpovědi. To znamená, že každá hodnota sumy koeficientů determinace je složená z dvanácti dílčích hodnot koeficientů determinace daných rotací měsíců. Určení optimální délky předpovědi bylo provedeno pomocí průměrných hodnot koeficientů determinace. Průměry byly stanoveny z jednotlivých sloupců v tab. 5, které obsahují sumy koeficientů determinace odpovídající předpovědím jednoho až dvanácti měsíců.

Tab. 5 Výpis jednotlivých sum koeficientů determinace pro danou délku předpovědi vpřed

	1 měsíc	2 měsíce	3 měsíce	4 měsíce	5 měsíců	6 měsíců
rotace	koeficient determinace					
1	3.450	2.298	1.453	3.064	2.270	1.748
2		1.961	0.956	1.767	1.623	1.957
3			1.499	2.081	1.033	1.570
4				7.529	4.256	4.375
5					3.568	3.503
6						4.053
7						
8						
9						
10						
11						
12						
	7 měsíců	8 měsíců	9 měsíců	10 měsíců	11 měsíců	12 měsíců
rotace	koeficient determinace					
1	2.782	1.149	0.970	1.475	0.892	0.802
2	1.548	0.992	1.872	1.232	1.597	1.172
3	2.016	2.207	1.892	2.243	1.853	0.840
4	4.557	3.627	3.725	2.467	1.365	1.825
5	3.619	3.753	3.203	2.929	3.220	2.913
6	4.630	5.209	4.037	4.086	4.106	3.213
7	2.969	4.748	4.582	3.354	1.777	4.343
8		3.196	3.458	3.022	3.313	3.923
9			2.627	5.076	3.321	3.047
10				3.336	2.188	2.685
11					1.894	3.329
12						2.837

Tab. 6 Porovnání průměrných sum koeficientů determinace při stanovení optimální délky předpovědi vpřed

počet předpovídaných měsíců	koeficient determinace
1	3.45
2	2.13
3	1.30
4	3.61
5	2.55
6	2.87
7	3.16
8	3.11
9	2.93
10	2.92
11	2.32
12	2.58
MAX	3.61
PRŮMĚR	2.74

Největší průměrná hodnota ze sloupců sum koeficientů determinace představuje optimální délku předpovědi. Z tab. 6 lze určit, že optimální délka předpovědi se pohybuje v oblasti čtyř měsíců vpřed. Červeně označené hodnoty jsou nejvyšší průměrné hodnoty koeficientů determinace a modře označené hodnoty jsou nejnižší.

5.4.3. Stanovení optimální předpovědi vzad a vpřed pro hybridní model neuronových sítí

Dalším krokem je nalezení vhodného počtu vstupních měsíců a nalezení optimální délky předpovědi pro hybridní model neuronových sítí. Postup hledání je shodný s postupem použitým pro klasický model neuronových sítí, kdy nejprve byl hledán vhodný počet vstupních měsíců (tab. 7 a 8).

Tab. 7 Výpočet sum koeficientů determinace při stanovení optimální předpovědi vzad

	1 měsíc	2 měsíce	3 měsíce	4 měsíce	5 měsíců	6 měsíců
rotace	koeficient determinace					
1	0.044	0.261	0	0.021	0.01	0.202
2	0.064	0.136	0.027	0.087	0.39	0.027
3	0.400	0.016	0.196	0.438	0.005	0.226
4	0.153	0.38	0.027	0.247	0.008	0.018
5	0.401	0.2	0.002	0.281	0.134	0
6	0.040	0	0	0.002	0.005	0.557
7	0.000	0.002	0.177	0	0.467	0.083
8	0.165	0.008	0.176	0.098	0.006	0.007
9	0.313	0.007	0.343	0.003	0.421	0.146
10	0.175	0.407	0.121	0.401	0.193	0.099
11	0.084	0.006	0.029	0.013	0.156	0.392
12	0.000	0.251	0.048	0.017	0.074	0.377
průměr	0.153	0.140	0.096	0.134	0.169	0.176
suma	1.839	1.674	1.146	1.608	1.869	2.134
	7 měsíců	8 měsíců	9 měsíců	10 měsíců	11 měsíců	12 měsíců
rotace	koeficient determinace					
1	0.049	0	0.435	0.013	0.019	0.02
2	0.404	0.343	0.028	0.523	0.228	0.063
3	0.431	0.024	0.481	0.215	0	0.264
4	0.044	0.641	0.139	0.057	0.648	0.177
5	0.501	0.061	0.052	0.275	0.02	0.002
6	0	0.065	0.282	0.005	0.08	0.162
7	0.01	0.156	0.269	0.004	0.133	0.083
8	0.105	0.533	0.194	0.077	0	0.167
9	0.031	0.309	0.26	0.034	0.409	0
10	0.408	0.393	0.066	0.008	0.396	0.136
11	0.696	0.093	0.034	0.024	0	0.008
12	0.051	0.007	0.374	0.526	0.923	0.494
průměr	0.228	0.219	0.218	0.147	0.238	0.131
suma	2.730	2.625	2.614	1.761	2.856	1.576

Tab. 8 Porovnání sum koeficientů determinace při stanovení vhodného počtu vstupních měsíců vzad

počet vstupních měsíců	koeficient determinace
1	1.84
2	1.67
3	1.15
4	1.61
5	1.87
6	2.13
7	2.73
8	2.63
9	2.61
10	1.76
11	2.86
12	1.58
MAX	2.86
PRŮMĚR	2.04

Pomocí tabulky (8) lze jedenáct vstupních měsíců prohlásit za vhodný počet při předpovídání hybridním modelem. Nejvyšší hodnota sumy R^2 byla nalezena pro jedenáct vstupních měsíců, ale podobných hodnot bylo dosaženo i s devíti vstupními měsíci jako u klasického modelu neuronových sítí. V tab. 8 jsou nejvyšší hodnoty sum koeficientů determinace označeny červeně a nejnižší hodnoty modře.

Dále následovalo stanovení optimální délky předpovědi vpřed (tab. 9 a 10).

Tab. 9 Výpis jednotlivých sum koeficientů determinace pro danou délku předpovědi vpřed

	1 měsíc	2 měsíce	3 měsíce	4 měsíce	5 měsíců	6 měsíců
rotace	koeficient determinace					
1	2.860	2.36	1.97	2.83	2.23	2.23
2		10.18	7.57	3.83	4.31	4.25
3			6.95	6.16	4.92	3.89
4				6.13	5.08	4.31
5					3.17	5.66
6						3.50
7						
8						
9						
10						
11						
12						
	7 měsíců	8 měsíců	9 měsíců	10 měsíců	11 měsíců	12 měsíců
rotace	koeficient determinace					
1	1.870	1.34	1.06	1.57	1.06	2.06
2	3.725	2.49	2.54	2.06	2.36	2.58
3	4.993	4.12	3.45	3.44	3.37	2.83
4	4.765	5.19	4.33	4.86	3.41	3.06
5	4.500	4.59	3.86	4.40	4.35	3.99
6	4.196	4.04	4.23	3.43	5.67	3.31
7	2.704	3.74	4.10	3.63	4.10	2.64
8		2.67	4.07	3.44	3.11	3.32
9			2.31	2.08	3.11	2.22
10				2.09	1.70	2.64
11					1.72	2.14
12						2.70

Tab. 10 Porovnání průměrných sum koeficientů determinace při stanovení optimální délky předpovědi vpřed

počet předpovídaných měsíců	koeficient determinace
1	2.86
2	6.27
3	5.50
4	4.74
5	3.94
6	3.97
7	3.82
8	3.52
9	3.33
10	3.10
11	3.09
12	2.79
MAX	6.27
PRŮMĚR	3.91

Největší průměrná suma koeficientů determinace pro hybridní model byla nalezena pro dva předpovídané měsíce vpřed. Při simulaci byly průtoky vygenerovány nezvykle příliš přesně oproti předpovědím jiných měsíců. Z toho důvodu nebyla předpověď na dva měsíce vpřed uvažována jako porovnatelná s ostatními. Další vysoké hodnoty průměrných sum koeficientů determinace vykazovaly tři a čtyři předpovídané měsíce vpřed.

Hybridní model vykazoval průměrné hodnoty sum koeficientů determinace mírně nižší než klasický model neuronových sítí při stanovení optimálního počtu vstupních měsíců.

5.5. Sestavení předpovědi pro aplikaci na vodohospodářskou soustavu

Pro předpovědi, které byly aplikovány na vodohospodářské soustavě nádrží Brno a Vír I v navazující diplomové práci, byl použit klasický model neuronových sítí. Klasický model neuronových sítí byl zvolen pro aplikaci na vodohospodářskou soustavu, po srovnání s modelem hybridním, který vykazoval předpovědi průměrných měsíčních průtoků méně přesněji. Počet vstupních měsíců, který byl hledán v předchozí kapitole, byl stanoven na devět. Délka předpovědi byla stanovena optimalizačním modelem, který předpovězené průtoky používá. Počet předpovídaných měsíců vpřed byl určen z bakalářské práce [18] na 1, 2, 4, 6, 10 a 12. Předpovědi byly aplikovány pro měrné profily Dalečín a Skryje.


5.5.1. Předpovědi průměrných měsíčních průtoků pro měrný profil Dalečín

V tab. 11 je ukázka předpovědí aplikovaných pro vodohospodářské účely pro měrný profil Dalečín. Pro porovnání naměřených a předpovězených průtoků byl zvolen krok předpovědi na dvanáct měsíců vpřed s devíti měsíci vstupními. V tab. 11 jsou naměřené historické průtoky, které jsou označeny modrým pruhem, a průtoky předpovězené klasickým modelem, které jsou označeny červeným pruhem. Hnědě a modře označené roky jsou roky, které byly zvoleny pro validaci. Modře označené roky jsou shodné s předpovídanými roky v bakalářské práci.


Tab. 11 Porovnání naměřených a předpovězených průměrných měsíčních průtoků pro měrný profil Dalečín

naměřené průtoky												
měsíc	červenec	srpen	září	říjen	listopad	prosinec	leden	únor	březen	duben	květen	červen
rok	1	2	3	4	5	6	7	8	9	10	11	12
51	1.5	0.8	1.0	1.2	1.1	2.1	3.4	10.3	6.8	4.7	1.8	1.7
52	3.8	1.7	1.4	0.9	3.9	2.5	3.9	3.8	13.0	5.4	2.1	1.4
53	1.6	5.4	1.6	1.5	0.9	1.6	1.4	1.7	10.1	17.4	6.5	3.0
54	0.9	0.5	2.9	2.1	3.7	2.0	4.0	6.9	8.4	2.9	1.6	1.3
55	1.6	1.2	1.1	1.3	5.6	6.2	5.4	3.8	7.5	3.8	2.2	1.6
56	5.3	2.3	1.3	2.4	1.5	2.4	1.7	2.8	14.8	5.8	1.7	2.7
57	2.0	3.7	6.0	2.9	2.5	3.5	3.4	2.6	10.3	7.0	5.7	6.4
12	6.2	2.3	2.1	1.8	3.5	3.1	2.3	2.0	12.4	10.2	7.2	8.4
38	1.6	2.6	0.7	0.9	1.3	1.2	2.1	0.9	1.8	1.8	3.5	1.9
40	1.0	0.5	1.3	1.2	1.0	1.5	2.8	1.6	6.5	5.4	1.7	1.3
předpovězené průtoky												
měsíc	červenec	srpen	září	říjen	listopad	prosinec	leden	únor	březen	duben	květen	červen
rok	1	2	3	4	5	6	7	8	9	10	11	12
51	1.3	1.7	2.3	1.3	2.6	2.4	2.9	5.5	7.9	5.4	2.8	3.4
52	1.2	1.5	2.9	1.1	3.6	2.9	3.5	8.1	11.5	4.1	2.4	3.6
53	1.4	2.0	1.2	1.6	0.9	1.5	1.9	0.8	1.4	7.9	3.5	3.1
54	1.2	1.6	2.7	1.2	3.4	2.8	3.3	7.4	10.5	4.5	2.5	3.5
55	1.3	1.7	2.4	1.3	2.8	2.5	3.0	6.0	8.5	5.2	2.7	3.4
56	1.3	1.8	2.0	1.4	2.2	2.1	2.7	4.2	6.1	6.1	3.0	3.3
57	1.3	1.7	2.2	1.3	2.5	2.3	2.9	5.2	7.4	5.6	2.9	3.4
12	1.3	1.7	2.3	1.3	2.6	2.4	2.9	5.4	7.8	5.5	2.8	3.4
38	1.4	2.0	1.4	1.5	1.2	1.6	2.1	1.6	2.6	7.4	3.4	3.1
40	1.3	1.9	1.8	1.4	1.8	2.0	2.5	3.4	4.9	6.5	3.1	3.3


Na obr. 36 až 45 jsou vyobrazeny závislosti naměřených a předpovězených průtoků na zvolené délce předpovědi. Grafy obsahují křivky naměřených průtoků označených modře a předpovězených průtoků označených červeně. Byly předpovídaný roky 51 až 57 společně s roky 12, 38 a 40.




Obr. 36 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 51. rok




Obr. 37 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 52. rok




Obr. 38 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 53. rok




Obr. 39 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 54. rok




Obr. 40 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 55. rok




Obr. 41 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 56. rok




Obr. 42 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 57. rok



Obr. 43 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 12. rok



Obr. 44 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 38. rok



Obr. 45 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 40. rok


5.5.2. Předpovědi průměrných měsíčních průtoků pro měrný profil Skryje

Pro měrný profil Skryje byly společně s roky 12, 38 a 40 zvoleny předpovídané roky 50 až 56. Délka předpovědi vzad byla zvolena pro předpovídání klasickým modelem neuronových sítí na devět měsíců vzad. Délka předpovědi byla zvolena na dvanáct měsíců vpřed stejně jako pro měrný profil Dalečín. V tab. 12 jsou naměřené průtoky označeny modrým pruhem a předpovězené průtoky červeným pruhem.


Tab. 12 Porovnání naměřených a předpovězených průměrných měsíčních průtoků pro měrný profil Skryje

naměřené průtoky												
měsíc	červenec	srpen	září	říjen	listopad	prosinec	leden	únor	březen	duben	květen	červen
rok	1	2	3	4	5	6	7	8	9	10	11	12
50	0.4	0.2	0.3	0.3	0.3	0.6	1.2	4.6	2.6	1.6	0.6	0.4
51	1.0	0.5	0.4	0.5	1.3	0.9	2.1	1.8	5.7	2.5	0.9	0.5
52	0.4	1.1	0.7	0.7	0.5	0.8	0.7	0.7	5.1	8.5	2.8	1.0
53	0.3	0.2	0.5	0.5	1.4	0.9	1.6	3.7	4.0	1.1	0.7	0.5
54	0.7	0.6	0.4	0.5	1.9	2.7	2.2	1.5	2.4	1.4	0.8	0.6
55	3.1	1.1	0.5	0.7	0.6	1.1	0.8	1.2	7.8	2.3	0.6	0.7
56	1.2	2.5	1.9	1.6	1.2	1.3	1.5	1.2	5.5	2.8	2.3	4.2
12	3.8	1.1	0.9	0.9	1.2	1.3	1.4	1.6	7.3	5.5	4.3	6.0
38	0.5	1.1	0.4	0.4	0.5	0.6	0.8	0.3	0.9	0.8	1.2	0.8
40	0.3	0.2	0.4	0.5	0.4	0.7	1.4	0.6	2.9	2.1	0.8	0.5
předpovězené průtoky												
měsíc	červenec	srpen	září	říjen	listopad	prosinec	leden	únor	březen	duben	květen	červen
rok	1	2	3	4	5	6	7	8	9	10	11	12
50	1.1	1.2	1.0	0.8	0.7	0.8	0.9	1.5	4.5	4.2	1.2	2.0
51	0.9	0.9	0.8	0.6	0.7	0.8	1.0	1.2	3.3	3.0	1.3	1.5
52	1.4	1.6	1.3	1.0	0.7	0.8	0.9	1.8	6.0	5.9	1.1	2.8
53	1.0	1.1	0.9	0.8	0.7	0.8	1.0	1.4	4.2	3.9	1.2	1.9
54	0.4	0.3	0.4	0.3	0.7	0.9	1.0	0.8	1.1	0.6	1.6	0.4
55	0.9	0.9	0.8	0.6	0.7	0.8	1.0	1.3	3.4	3.0	1.3	1.5
56	1.4	1.6	1.2	1.0	0.7	0.8	0.9	1.8	5.9	5.8	1.1	2.7
12	1.6	1.9	1.4	1.2	0.7	0.7	0.9	2.0	7.2	7.1	0.9	3.3
38	0.6	0.6	0.6	0.5	0.7	0.9	1.0	1.0	2.0	1.6	1.5	0.9
40	0.7	0.7	0.6	0.5	0.7	0.9	1.0	1.0	2.3	1.9	1.4	1.0


Na obr. 46 až 55 jsou zobrazeny závislosti průtoků na délce předpovědi, stejným způsobem jak bylo zvoleno i pro měrný profil Dalečín, kde modré křivky označují naměřené hodnoty průtoků a červené křivky označují předpovězené průtoky.




Obr. 46 Porovnání předpovězených průtoků v měrném profilu Skryje pro 50. rok




Obr. 47 Porovnání předpovězených průtoků v měrném profilu Skryje pro 51. rok




Obr. 48 Porovnání předpovězených průtoků v měrném profilu Skryje pro 52. rok




Obr. 49 Porovnání předpovězených průtoků v měrném profilu Skryje pro 53. rok




Obr. 50 Porovnání předpovězených průtoků v měrném profilu Skryje pro 54. rok




Obr. 51 Porovnání předpovězených průtoků v měrném profilu Skryje pro 55. rok




Obr. 52 Porovnání předpovězených průtoků v měrném profilu Skryje pro 56. rok



Obr. 53 Porovnání předpovězených průtoků v měrném profilu Skryje pro 12. rok



Obr. 54 Porovnání předpovězených průtoků v měrném profilu Skryje pro 38. rok



Obr. 55 Porovnání předpovězených průtoků v měrném profilu Skryje pro 40. rok

6. SHRUTÍ VÝSLEDKŮ

Shrnutí výsledků bylo prezentováno na grafech o třech křivkách, kde první křivka představuje naměřené průtoky, a zbývající křivky představují předpovězené průtoky pomocí klasického nebo hybridního modelu neuronových sítí v první části. V druhé části budou křivky představovat předpovězené průtoky klasickým modelem neuronových sítí a předpovězené průtoky pomocí generátoru LTMA a metody Monte Carlo. Další porovnání předpovězených průtoků bylo provedeno pomocí absolutních hodnot sum odchylek mezi porovnávanými průtoky a pomocí hodnot koeficientů determinace. Předpovědi průměrných měsíčních průtoků budou prezentovány ve dvou rovinách.

V první části bude porovnávána úspěšnost předpovědí klasického a hybridního modelu neuronových sítí (tab. 13) pro měrný profil Dalečín. Počet vstupních měsíců pro klasický model neuronových sítí byl zvolen na devět měsíců vzad a pro hybridní model byl zvolen na jedenáct měsíců vzad. Délka předpovědi byla zvolena shodně na čtyři předpovídané měsíce vpřed podle kapitoly 5.4., kde byla pro oba modely společně zjištěna délka předpovědi na čtyři měsíce vpřed jako nejpřesnější.

V druhé části budou porovnány předpovědi průtoků použitých pro vodohospodářské účely s předpověďmi průtoků z bakalářské práce [17] (tab. 15). Výsledky budou prezentovány pouze pro délku předpovědi na dvanáct měsíců vpřed, která byla určena předpovědním modelem použitým v bakalářské práci [17]. Předpovědi byly porovnávány pro měrný profil Dalečín a pro měrný profil Skryje.


6.1. Porovnání předpovězených průtoků klasickým a hybridním modelem

V této kapitole bylo provedeno porovnání předpovědí průměrných měsíčních průtoků klasickým a hybridním modelem neuronových sítí. V tab. 13 jsou modrým pruhem označeny hodnoty naměřených historických průtoků, červeným pruhem jsou označeny hodnoty průtoků předpovězené klasickým modelem a zeleným pruhem jsou označeny hodnoty průtoků předpovězené hybridním modelem.


Tab. 13 Porovnání průtoků předpovězených klasickým a hybridním předpovědním modelem neuronových sítí

naměřené průtoky				
měsíc	červenec	srpen	září	říjen
rok	1	2	3	4
52	3.9	2.0	2.1	1.9
53	2.3	2.2	3.9	3.7
54	1.0	1.4	1.1	2.1
55	1.0	1.2	3.9	2.5
56	1.4	0.9	0.9	1.6
57	1.6	1.5	3.7	2.0
58	2.9	2.1	5.6	6.2
59	1.1	1.3	1.5	2.4
60	1.3	2.4	2.5	3.5
61	6.0	2.9	2.2	5.0
předpovězené průtoky klasickým modelem				
měsíc	červenec	srpen	září	říjen
rok	1	2	3	4
52	1.8	1.1	1.4	1.8
53	2.3	1.6	2.7	3.3
54	1.7	1.1	1.3	1.7
55	1.9	1.2	1.8	2.3
56	1.9	1.2	1.7	2.1
57	1.9	1.2	1.8	2.2
58	2.9	2.0	3.9	4.6
59	1.7	1.1	1.3	1.7
60	2.6	1.8	3.3	4.0
61	2.2	1.5	2.4	3.0
předpovězené průtoky hybridním modelem				
měsíc	červenec	srpen	září	říjen
rok	1	2	3	4
52	2.4	1.4	2.5	2.7
53	2.7	1.5	3.2	3.1
54	2.1	1.2	1.9	2.4
55	2.3	1.3	2.2	2.6
56	1.7	1.0	1.2	1.9
57	2.5	1.4	2.7	2.8
58	3.4	1.9	4.5	3.8
59	2.1	1.2	1.9	2.4
60	2.3	1.3	2.2	2.6
61	2.6	1.5	3.0	3.0


Na obr. 56 až 65 jsou uvedeny závislosti naměřených a předpovězených průtoků na délce předpovědi v měsících, kde modrá křivka představuje naměřené historické průtoky, červená křivka označuje průtoky předpovězené klasickým modelem a zelená křivka označuje průtoky předpovězené hybridním modelem. Na obr. 56 až 65 jsou zobrazeny předpovídané roky 52 až 61, které odpovídají historickým rokům naměřeným v měrném profilu Dalečín.




Obr. 56 Porovnání předpovězených průtoků pro 52. rok




Obr. 57 Porovnání předpovězených průtoků pro 53. rok




Obr. 58 Porovnání předpovězených průtoků pro 54. rok




Obr. 59 Porovnání předpovězených průtoků pro 55. rok




Obr. 60 Porovnání předpovězených průtoků pro 56. rok




Obr. 61 Porovnání předpovězených průtoků pro 57. rok




Obr. 62 Porovnání předpovězených průtoků pro 58. rok



Obr. 63 Porovnání předpovězených průtoků pro 59. rok



Obr. 64 Porovnání předpovězených průtoků pro 60. rok



Obr. 65 Porovnání předpovězených průtoků pro 61. rok

Předpovědi provedené klasickým modelem neuronových sítí vizuálně vypadají mírně lépe, než předpovědi získané pomocí hybridního modelu. Průběhy předpovězených průtoků získané klasickým modelem jsou proti křivkám průtoků získaných hybridním modelem mírně pesimističtější. To znamená, že většina křivek klasického modelu udává mírně nižší hodnoty průtoků než model hybridní. V tab. 14 je uvedeno porovnání předpovědí klasického (označený červeně) a hybridního modelu (označený zeleně) pomocí odchylek mezi jednotlivými průtoky. Výpočet odchylek byl proveden pomocí absolutních hodnot rozdílů mezi naměřenými a předpovídanými průtoky, které byly získány pomocí určitého

předpovědního modelu. Z absolutních hodnot odchylek byly dále vypočítány sumy a průměry z jednotlivých odchylek.

Tab. 14 Porovnání předpovědních modelů pomocí odchylek mezi předpovídanými průtoky

odchylky stanovené pro klasický model					odchylky stanovené pro hybridní model				
měsíc	červenec	srpen	září	říjen	měsíc	červenec	srpen	září	říjen
rok	1	2	3	4	rok	1	2	3	4
52	2.14	0.88	0.62	0.04	52	1.54	0.62	0.40	0.79
53	0.00	0.60	1.19	0.39	53	0.40	0.61	0.71	0.58
54	0.75	0.34	0.26	0.33	54	1.14	0.18	0.85	0.31
55	0.90	0.00	2.10	0.16	55	1.22	0.06	1.69	0.10
56	0.50	0.28	0.83	0.48	56	0.35	0.10	0.30	0.30
57	0.35	0.29	1.92	0.25	57	0.92	0.09	1.00	0.83
58	0.08	0.04	1.74	1.52	58	0.43	0.15	1.16	2.34
59	0.64	0.23	0.19	0.67	59	1.02	0.07	0.39	0.03
60	1.28	0.60	0.82	0.50	60	0.94	1.11	0.27	0.95
61	3.78	1.39	0.27	2.04	61	3.35	1.35	0.84	2.03
suma	10.42	4.65	9.95	6.39	suma	11.31	4.33	7.63	8.25
průměr	1.04	0.47	1.00	0.64	průměr	1.13	0.43	0.76	0.82
suma celkem		31.42			suma celkem		31.52		
průměr celkem		0.79			průměr celkem		0.79		


6.2. Porovnání předpovězených průtoků klasickým modelem a modelem typu ARMA

V tab. 15 jsou uvedeny naměřené průtoky označené modrým pruhem společně s předpovězenými průtoky klasickým modelem, které jsou označeny červeným pruhem, a s předpovězenými průtoky modelem typu ARMA, které jsou označeny zeleným pruhem. Průtoky předpovězené modelem typu ARMA byly převzaty z bakalářské práce [17]. Z bakalářské práce byly použity předpovědi průtoků na dvanáct měsíců dopředu, které odpovídají kvantilu 50. Průtoky předpovězené klasickým modelem byly nastaveny s devíti měsíci vstupními a na dvanáct měsíců předpovídaných pro měrný profil Dalečín.


Tab. 15 Porovnání předpovězených průtoků klasickým modelem neuronových sítí a modelem typu ARMA v měrném profilu Dalečín

naměřené průtoky												
měsíc	červenec	srpen	září	říjen	listopad	prosinec	leden	únor	březen	duben	květen	červen
rok	1	2	3	4	5	6	7	8	9	10	11	12
12	6.2	2.3	2.1	1.8	3.5	3.1	2.3	2.0	12.4	10.2	7.2	8.4
38	1.6	2.6	0.7	0.9	1.3	1.2	2.1	0.9	1.8	1.8	3.5	1.9
40	1.0	0.5	1.3	1.2	1.0	1.5	2.8	1.6	6.5	5.4	1.7	1.3
předpovězené průtoky klasickým modelem												
měsíc	červenec	srpen	září	říjen	listopad	prosinec	leden	únor	březen	duben	květen	červen
rok	1	2	3	4	5	6	7	8	9	10	11	12
12	1.3	1.7	2.3	1.3	2.6	2.4	2.9	5.4	7.8	5.5	2.8	3.4
38	1.4	2.0	1.4	1.5	1.2	1.6	2.1	1.6	2.6	7.4	3.4	3.1
40	1.3	1.9	1.8	1.4	1.8	2.0	2.5	3.4	4.9	6.5	3.1	3.3
předpovězené průtoky v bakalářské práci generátorem LTMA												
měsíc	červenec	srpen	září	říjen	listopad	prosinec	leden	únor	březen	duben	květen	červen
rok	1	2	3	4	5	6	7	8	9	10	11	12
12	1.6	2.5	2.2	2.4	3.5	2.8	3.8	3.7	9.1	4.4	2.3	1.6
38	1.2	0.7	0.7	1.0	1.2	2.4	1.9	4.7	7.8	7.5	2.9	1.4
40	1.1	0.7	1.2	1.7	1.1	1.8	3.7	4.9	6.5	5.8	3.2	1.7


Na následujících obrázcích 66 až 68 jsou zobrazeny závislosti naměřených a předpovídaných průtoků na předpovídané délce v měsících, kde modrá křivka představuje naměřené hodnoty průtoků, červená křivka představuje předpovězené hodnoty průtoků klasickým modelem neuronových sítí a zelená křivka představuje předpovězené hodnoty průtoků modelem typu ARMA. Na obr. 66 až 68 jsou porovnány průtoky pro roky 12, 38 a 40 pro měrný profil Dalečín.



Obr. 66 Porovnání předpovězených průtoků pro 12. rok v měrném profilu Dalečín



Obr. 67 Porovnání předpovězených průtoků pro 38. rok v měrném profilu Dalečín




Obr. 68 Porovnání předpovězených průtoků pro 40. rok v měrném profilu Dalečín


V tab. 16 jsou uvedeny naměřené průtoky označené modrým pruhem společně s předpovězenými průtoky klasickým modelem označenými červeným pruhem a s předpovězenými průtoky modelem typu ARMA označenými zeleným pruhem. Rozdílem v porovnání proti předchozím předpovězeným hodnotám průtoků v tab. 14 je jiný měrný profil, kde hodnoty v tab. 15 jsou určeny pro měrný profil Skryje.

Tab. 16 Porovnání předpovězených průtoků klasickým modelem neuronových sítí a modelem typu ARMA v měrném profilu Skryje


naměřené průtoky												
měsíc	listopad	prosinec	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen
rok	1	2	3	4	5	6	7	8	9	10	11	12
12	1.2	1.3	1.4	1.6	7.3	5.5	4.3	6.0	3.8	1.1	0.9	0.9
38	0.5	0.6	0.8	0.3	0.9	0.8	1.2	0.8	0.5	1.1	0.4	0.4
40	0.4	0.7	1.4	0.6	2.9	2.1	0.8	0.5	0.3	0.2	0.4	0.5
předpovězené průtoky klasickým modelem												
měsíc	listopad	prosinec	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen
rok	1	2	3	4	5	6	7	8	9	10	11	12
12	0.8	0.9	0.9	1.5	2.1	3.1	1.8	1.5	1.8	1.7	1.2	0.6
38	0.7	0.8	1.0	0.9	2.7	2.3	1.1	1.2	0.7	0.5	0.6	0.6
40	0.7	0.8	1.0	0.7	2.9	2.1	0.9	1.1	0.3	0.2	0.4	0.5
předpovězené průtoky v bakalářské práci generátorem LTMA												
měsíc	listopad	prosinec	leden	únor	březen	duben	květen	červen	červenec	srpen	září	říjen
rok	1	2	3	4	5	6	7	8	9	10	11	12
12	1.3	1.2	1.3	1.5	4.8	1.4	0.9	0.8	0.8	1.4	0.8	1.1
38	0.5	1.1	0.9	2.9	4.4	3.2	1.4	0.6	0.5	0.3	0.2	0.3
40	0.4	0.7	1.5	2.4	3.4	2.0	1.3	0.8	0.5	0.3	0.5	0.7



Obr. 69 Porovnání předpovězených průtoků pro 12. rok v měrném profilu Skryje



Obr. 70 Porovnání předpovězených průtoků pro 38. rok v měrném profilu Skryje



Obr. 71 Porovnání předpovězených průtoků pro 40. rok v měrném profilu Skryje

V tab. 17 a 18 je zobrazeno porovnání klasického modelu neuronových sítí s modelem založeným na generátoru LTMA. Porovnání bylo provedeno pomocí hodnot absolutních odchylek mezi naměřenými a předpovídanými průtoky. Hodnoty předpovědí průměrných měsíčních průtoků získaných klasickým modelem jsou v tab. 17 a 18 označeny červeným pruhem a zeleným pruhem jsou označeny hodnoty předpovědí průměrných měsíčních průtoků získaných modelem založeným na generátoru LTMA. V tab. 17 je porovnání modelů pro měrný profil Skryje, kdy model založený na generátoru LTMA vykazuje mírně vyšší průměrnou i celkovou hodnotu odchylky oproti klasickému modelu neuronových sítí.

Z tab. 18 je patrné, že model založený na generátoru LTMA generoval průtoky opět s mírně vyššími odchylkami než klasický model neuronových sítí.

Tab. 17 Porovnání předpovědních modelů pomocí odchylek mezi předpovídanými průtoky pro měrný profil Dalečín

odchylky stanovené pro klasický model												
měsíc	červenec	srpen	září	říjen	listopad	prosinec	leden	únor	březen	duben	květen	červen
rok	1	2	3	4	5	6	7	8	9	10	11	12
12	4.88	0.63	0.17	0.51	0.85	0.71	0.62	3.44	4.66	4.76	4.33	5.02
38	0.19	0.66	0.67	0.63	0.09	0.43	0.03	0.76	0.72	5.63	0.06	1.26
40	0.36	1.30	0.44	0.26	0.84	0.53	0.36	1.82	1.60	1.13	1.40	1.96
suma	5.43	2.60	1.27	1.40	1.78	1.67	1.02	6.02	6.98	11.52	5.78	8.24
průměr	1.81	0.87	0.42	0.47	0.59	0.56	0.34	2.01	2.33	3.84	1.93	2.75
suma celkem	53.71											
průměr celkem	1.49											
odchylky stanovené pro model založený na generátoru LTMA												
měsíc	červenec	srpen	září	říjen	listopad	prosinec	leden	únor	březen	duben	květen	červen
rok	1	2	3	4	5	6	7	8	9	10	11	12
12	4.55	0.19	0.07	0.63	0.06	0.32	1.49	1.68	3.31	5.87	4.87	6.78
38	0.33	1.92	0.03	0.06	0.12	1.17	0.20	3.83	5.97	5.74	0.57	0.43
40	0.12	0.19	0.13	0.55	0.12	0.38	0.83	3.36	0.08	0.36	1.49	0.40
suma	5.00	2.30	0.24	1.25	0.30	1.87	2.52	8.87	9.36	11.97	6.93	7.62
průměr	1.67	0.77	0.08	0.42	0.10	0.62	0.84	2.96	3.12	3.99	2.31	2.54
suma celkem	58.20											
průměr celkem	1.62											

Tab. 18 Porovnání předpovědních modelů pomocí odchylek mezi předpovídanými průtoky pro měrný profil Skryje

odchylky stanovené pro klasický model												
měsíc	červenec	srpen	září	říjen	listopad	prosinec	leden	únor	březen	duben	květen	červen
rok	1	2	3	4	5	6	7	8	9	10	11	12
12	0.38	0.42	0.50	0.08	5.20	2.38	2.55	4.55	1.94	0.60	0.23	0.28
38	0.21	0.21	0.19	0.58	1.81	1.50	0.01	0.41	0.15	0.53	0.20	0.20
40	0.25	0.13	0.38	0.14	0.07	0.00	0.17	0.59	0.07	0.00	0.01	0.01
suma	0.84	0.76	1.07	0.80	7.08	3.88	2.73	5.55	2.16	1.13	0.43	0.48
průměr	0.28	0.25	0.36	0.27	2.36	1.29	0.91	1.85	0.72	0.38	0.14	0.16
suma celkem	26.92											
průměr celkem	0.75											
odchylky stanovené pro model založený na generátoru LTMA												
měsíc	červenec	srpen	září	říjen	listopad	prosinec	leden	únor	březen	duben	květen	červen
rok	1	2	3	4	5	6	7	8	9	10	11	12
12	0.10	0.03	0.02	0.12	2.50	4.08	3.43	5.26	2.98	0.35	0.13	0.26
38	0.04	0.48	0.08	2.52	3.56	2.40	0.20	0.18	0.01	0.78	0.18	0.04
40	0.01	0.06	0.10	1.80	0.49	0.09	0.53	0.28	0.12	0.11	0.16	0.18
suma	0.15	0.57	0.21	4.43	6.55	6.56	4.16	5.72	3.11	1.24	0.47	0.48
průměr	0.05	0.19	0.07	1.48	2.18	2.19	1.39	1.91	1.04	0.41	0.16	0.16
suma celkem	33.64											
průměr celkem	0.93											

Hodnoty absolutních sum celkových odchylek i průměrné hodnoty celkových odchylek vyšly menší pro klasický model neuronových sítí. Pro měrný profil Skryje vyšly hodnoty odchylek výrazně nižší než pro měrný profil Dalečín.

V tab. 19 je uvedeno porovnání klasické modelu neuronových sítí s modelem založeným na generátoru LTMA, kdy úspěšnost předpovědních modelů byla porovnána pomocí koeficientů determinace. R^2 byly stanoveny porovnáním jednotlivých průměrných měsíčních předpovídaných průtoků pro určitý předpovědní model s průtoky naměřenými. Z tab. 19 lze pozorovat, že koeficienty determinace určené pro klasický model neuronových sítí vycházely mírně lépe než koeficienty získané při předpovědích pomocí generátoru LTMA.

Tab. 19 Porovnání předpovědních modelů pomocí koeficientů determinace

Dalečín				Skryje			
rok	12	38	40	rok	12	38	40
klasický model				klasický model			
R^2	0.440	0.121	0.725	R^2	0.512	0.149	0.924
generátor LTMA				generátor LTMA			
R^2	0.308	0.007	0.770	R^2	0.245	0.033	0.727

7. ZÁVĚR

V diplomové práci byly testovány předpovědní modely založené na principech a teorii neuronových sítí. Neuronové sítě jsou v současné době ve světě velmi populární, a to v mnoha různých odvětvích. Stále častěji bývají využívány i ve vodním hospodářství jako vhodné nástroje nejenom k predikcím hodnot průtoků, k určování šíření znečištění v nádržích, ale také k dalším druhům optimalizací ve vodním hospodářství.

Díky svým výhodám, mezi které patří hlavně rychlost učení a adaptace na neznámé prostředí, jsou vhodným prvkem při předpovídání průměrných měsíčních průtoků. Moderním trendem je snaha o vytváření pravidel pro řízení vodohospodářských nádrží a soustav nádrží na základě předpovědí. Proto v diplomové práci je porovnáváno několik předpovědních modelů neuronových sítí a několik přístupů při nastavování modelu.

Předpovědi byly prováděny systémem rotací měsíců, kdy pro určitý počet předpovídaných měsíců při každém kroku byla matice vstupních hodnot posunuta o jedno místo, až dokud nebyla provedena rotace celého roku. Z takto sestavených předpovědí byla hledána nejlepší z nich, která vykazovala nejvyšší hodnoty koeficientů determinace. Pro vyhodnocení úspěšnosti předpovědí byly použity i jiné koeficienty, ale nejlépe úspěšnost předpovědi vystihoval právě koeficient determinace R^2 , který je ve světě nejčastěji používaný při posouzení lineární vazby mezi dvěma soubory hodnot.

Při hodnocení první části práce, tedy hodnocení klasického modelu s hybridním modelem neuronových sítí dosahovaly nejlepších hodnot R^2 sítě s optimálním počtem vstupních a předpovídaných měsíců. U klasického modelu neuronových sítí byla nejlepší předpověď vyhodnocena pro čtyři měsíce dopředu s devíti měsíci vstupními. Pro hybridní model neuronových sítí bylo dosaženo nejlepších výsledků s jedenácti vstupními měsíci a třemi předpovídanými měsíci vpřed. Porovnáním modelů pomocí hodnoty absolutní odchylky byla pro klasický model vypočtena hodnota sumy celkové odchylky o velikosti 31,42 proti hybridnímu modelu pro, který hodnota sumy celkové odchylky vyšla 31,52. Klasický model pak v porovnání sumy odchylek vycházel pro sestavení předpovědi nepatrně lépe.

Při porovnání předpovědí průtoků mezi klasickým modelem neuronových sítí a předpovědním modelem LTMA použitým v bakalářské práci, které byly dále použity pro účely řízení soustavy nádrží, lze výsledky zhodnotit následovně. Velikosti absolutních hodnot sum celkových odchylek při porovnání klasického modelu neuronových sítí a modelu založeného na generátoru LTMA vycházely 53,71 pro klasický model a 58,20 pro generátor

LTMA v měrném profilu Dalečín. Pro měrný profil Skryje vycházely velikosti absolutních hodnot sum celkových odchylek 26,92 pro klasický model a 33,64 pro generátor LTMA. Dalším prvkem hodnocení předpovědních modelů bylo hodnocení pomocí koeficientů determinace, kdy opět klasický model založený na neuronových sítích dosahoval lepších výsledků než model založený na generátoru LTMA.

Volba klasického modelu pro předpovědi aplikované na vodohospodářskou soustavu nádrží byla stanovena na základě získaných, lepších výsledků při větší délce předpovědi. Větší délka předpovědi je důležitá pro optimalizační model, který používá předpovědi dlouhé až dvanáct měsíců.

Možnosti zlepšení předpovědí s využitím neuronových sítí mají svůj potenciál. Z prezentovaných výsledků je patrné, že v určitých případech je předpověď dobrá, ale v jiných zase nepřesná. Jedním z možných vysvětlení je rozkolísanost, či velká variabilita měsíčních průtoků. Neuronová síť si následně pamatuje silné podněty, které mohou být vyvolány právě více vodnými měsíci. Vše je dobře zřetelné na profilu Dalečín obr. 66 až 68, měsíc 9 a 10, stejně tak v profilu Skryje obr. 69 až 71, měsíc 5 a 6. Zde jsou zřetelné vodné měsíce 9 a 10 na obr. 66 a 68 a na obr. 67 lze pozorovat, jak si předpovězené průtoky tento trend uchovaly. Stejné chování je patrné i v profilu Skryje v měsíci 5 a 6. Jedním z cílů diplomové práce je předpověď průměrných měsíčních průtoků převážně v málo vodném období. V tomto případě se naskytá prostor pro další práci a tím je například úprava vstupních, historických dat z hlediska separace extrémně vodných průtoků. Po separaci extrémních průtoků by byla zlepšena možnost pozorovat posuny a hydrologické vazby jednotlivých měsíců především v málo vodných epizodách. Například u málo vodných měsíců, ve kterých průtoky méně kolísají, by mohla neuronová síť lépe zachytit průběhy průtoků.

Jiná cesta ke zlepšení předpovědí by mohla být volba odlišného generátoru umělých řad pro vytvoření kvalitnějších vstupů do neuronové sítě. Další možností, vedoucí ke zpřesnění předpovědí, je volba jiného intervalu hodnot určovaného při normalizaci dat a s ním související změna topologie sítě, nebo pro posouzení použitelnosti jednotlivých modelů zpracovat větší množství předpovídaných dat. S tím souvisejí další možnosti kombinací použitých vstupních měsíců, vztahujících se na určitou délku předpovědi. Tyto úpravy by vyžadovaly naprogramování rozsáhlejší automatizace při předpovídání průměrných měsíčních průtoků v programu Matlab.

V diplomové práci byly také testovány i další profily, které poskytl ČHMÚ pobočka Ostrava, ale výsledky nejsou v práci uvedeny.

8. SEZNAM POUŽITÝCH ZDROJŮ

[1] KAŠPÁREK, L. Odhad objemu nádrží potřebného pro kompenzaci poklesu odtoku vlivem klimatické změny, VÚV Praha, Praha, 2005.

[2] MILOŠ STARÝ, Užití umělých neuronových sítí v aplikované hydrologii, VUT FAST v Brně, 2004.

[3] PAVEL MENŠÍK, MILOŠ STARÝ, DANIEL MARTON, Použití předpovědních modelů průměrných měsíčních průtoků pro operativní řízení zásobní funkce vodních nádrží, Proceedings ITISE 2014, International work-conference on Time Series, 2014.

[4] JIŘÍ SÁZEL, MILOŠ STARÝ, Střednědobé předpovědi průtoků povrchových toků, Vodní hospodářství, water management, 1/2014.

[5] PAVEL FOŠUMPAUR, Použití umělých neuronových sítí pro operativní předpovědi říčních průtoků, Vodní hospodářství, 1999.

[6] DANIELA SVETLÍKOVÁ, Hybridný model priemerných mesačných prietokov pre povodie horného Hrona, Vodohospodársky spravodajca č. 9 – 10/2009.

[7] AMIR F. ATIYA, SUZAN M. EL-SHOURA, SAMIR I. SHAHEEN, MOHAMED S. EL-SHERIF, A Comparison Between Neural-Network Forecasting Techniques - Case Study: River Flow Forecasting, Ieee transactions on neural networks, březen 1999.

[8] CHUNTIAN CHENG, KWOKWING CHAU, YINGGUANG SUN, JIANYI LIN, Long-Term Prediction of Discharges in Manwan Reservoir Using Artificial Neural Network Models, Advances in Neural Networks – ISSN 2005.

[9] MILOŠ STARÝ, Hydrologie: MODUL 1. Studijní opory, VUT FAST v Brně, Brno 2005.

[10] MARTON DANIEL; STARÝ MILOŠ: LRM soft; LRM soft - generátor umělých měsíčních průtoků.

Dostupné z: < <http://uvhk.fce.vutbr.cz/software.php> >

[11] KOS ZDENĚK, Lineární regresní model a jeho aplikace v hydrologii, Vodní toky v Praze, Práce a studie 6, Praha 1969.

[12] P. KRAUSE, D. P. BOYLE, F. BÄSE, Comparison of different efficiency criteria for hydrological model assessment, Advances in Geosciences, 5, 89–97, 2005.

[13] <http://www.ivalo.cz/>[online], 2013 Vpress s.r.o

Dostupné z: <<http://www.ivalo.cz/cyklo-trasy/podel-ceskych-rek-svratka/>>

[14] <http://www.pmo.cz/>[online], 2014 Povodí Moravy, s.p.

Dostupné z: <http://www.pmo.cz/cz/media/tiskove-zpravy/ciste-povodi-svratky/>

[15] <http://www.chmi.cz/>[online], 2014 Český hydrometeorologický ústav

Dostupné z: <http://hydro.chmi.cz/hpps/hpps_prfbk_detail.php?seq=2505253>

[16] <http://www.chmi.cz/>[online], 2014 Český hydrometeorologický ústav

Dostupné z: <http://hydro.chmu.cz/hpps/hpps_prfbk_detail.php?seq=20491241>

[17] ŠELEPA MILAN, Předpověď průměrných měsíčních průtoků pro účely řízení soustavy nádrží, VUT FAST V Brně, Brno 2013.

[18] MICHALOVÁ LUCIE, Řízení vybrané vodohospodářské soustavy pomocí optimalizačního modelu, VUT FAST V Brně, Brno 2013.

SEZNAM OBRÁZKŮ

Obr. 1 Schéma umělého neuronu	8
Obr. 2 Koeficient korelace - nejlepší funkce.....	13
Obr. 3 Koeficient korelace - nejhorší funkce.	13
Obr. 4 Koeficient korelace - nejlepší funkce.....	14
Obr. 5 Ukázka R^2 – měřený průtok a předpovězený průtok.....	15
Obr. 6 Vodní tok Svratka [13].....	18
Obr. 7 Povodí Svratky s označením měrných profilů [14].....	19
Obr. 8 Evidenční list hlásného profilu č. 371[15]	20
Obr. 9 Evidenční list hlásného profilu č. 372a [16]	21
Obr. 10 Ukázka načítání vstupních dat v programu Matlab.....	25
Obr. 11 Ukázka načítání cílových dat v programu Matlab.....	26
Obr. 12 Ukázka načítání vzorových dat v programu Matlab	26
Obr. 13 Ukázka načtených dat uložených v Matlab Workspace	27
Obr. 14 Ukázka importovaných dat do Neural Network/Data Manager v programu Matlab	28
Obr. 15 Ukázka nastavení neuronové sítě v programu Matlab	29
Obr. 16 Ukázka nastavené neuronové sítě v programu Matlab.....	30
Obr. 17 Ukázka nastavení dat pro trénování neuronové sítě v programu Matlab	31
Obr. 18 Ukázka nastavení tréninkových parametrů v programu Matlab.....	32
Obr. 19 Ukázka průběhu trénování neuronové sítě v programu Matlab	32
Obr. 20 Graf průběhu trénování neuronové sítě v programu Matlab	33
Obr. 21 Ukázka simulace výstupů v programu Matlab	34
Obr. 22 Ukázka exportu dat do Matlab Workspace	34
Obr. 23 Ukázka trénování a simulace skriptem v programu Matlab.....	35
Obr. 24 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 1. rotaci	37
Obr. 25 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 2. rotaci	37
Obr. 26 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 3. rotaci	38
Obr. 27 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 4. rotaci	38
Obr. 28 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 5. rotaci	39
Obr. 29 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 6. rotaci	39
Obr. 30 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 7. rotaci	40
Obr. 31 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 8. rotaci	40
Obr. 32 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 9. rotaci	41
Obr. 33 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 10. rotaci	41
Obr. 34 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 11. rotaci	42
Obr. 35 Graf vyhodnocení úspěšnosti předpovědi a stanovení R^2 pro 12. rotaci	42
Obr. 36 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 51. rok	51
Obr. 37 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 52. rok	51
Obr. 38 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 53. rok	52
Obr. 39 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 54. rok	52
Obr. 40 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 55. rok	53
Obr. 41 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 56. rok	53
Obr. 42 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 57. rok	54
Obr. 43 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 12. rok	54
Obr. 44 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 38. rok	55
Obr. 45 Porovnání předpovězených průtoků v měrném profilu Dalečín pro 40. rok	55
Obr. 46 Porovnání předpovězených průtoků v měrném profilu Skryje pro 50. rok	56
Obr. 47 Porovnání předpovězených průtoků v měrném profilu Skryje pro 51. rok	57
Obr. 48 Porovnání předpovězených průtoků v měrném profilu Skryje pro 52. rok	57
Obr. 49 Porovnání předpovězených průtoků v měrném profilu Skryje pro 53. rok	58
Obr. 50 Porovnání předpovězených průtoků v měrném profilu Skryje pro 54. rok	58

Obr. 51 Porovnání předpovězených průtoků v měrném profilu Skryje pro 55. rok	59
Obr. 52 Porovnání předpovězených průtoků v měrném profilu Skryje pro 56. rok	59
Obr. 53 Porovnání předpovězených průtoků v měrném profilu Skryje pro 12. rok	60
Obr. 54 Porovnání předpovězených průtoků v měrném profilu Skryje pro 38. rok	60
Obr. 55 Porovnání předpovězených průtoků v měrném profilu Skryje pro 40. rok	61
Obr. 56 Porovnání předpovězených průtoků pro 52. rok	64
Obr. 57 Porovnání předpovězených průtoků pro 53. rok	64
Obr. 58 Porovnání předpovězených průtoků pro 54. rok	65
Obr. 59 Porovnání předpovězených průtoků pro 55. rok	65
Obr. 60 Porovnání předpovězených průtoků pro 56. rok	66
Obr. 61 Porovnání předpovězených průtoků pro 57. rok	66
Obr. 62 Porovnání předpovězených průtoků pro 58. rok	67
Obr. 63 Porovnání předpovězených průtoků pro 59. rok	67
Obr. 64 Porovnání předpovězených průtoků pro 60. rok	68
Obr. 65 Porovnání předpovězených průtoků pro 61. rok	68
Obr. 66 Porovnání předpovězených průtoků pro 12. rok v měrném profilu Dalečín	70
Obr. 67 Porovnání předpovězených průtoků pro 38. rok v měrném profilu Dalečín	71
Obr. 68 Porovnání předpovězených průtoků pro 40. rok v měrném profilu Dalečín	71
Obr. 69 Porovnání předpovězených průtoků pro 12. rok v měrném profilu Skryje	72
Obr. 70 Porovnání předpovězených průtoků pro 38. rok v měrném profilu Skryje	73
Obr. 71 Porovnání předpovězených průtoků pro 40. rok v měrném profilu Skryje	73

SEZNAM TABULEK

Tab. 1 Ukázka rotovaných hodnot průtoků pro měrný profil Dalečín	23
Tab. 2 Ukázka normalizovaných hodnot průtoků pro měrný profil Dalečín.....	24
Tab. 3 Výpočet sum koeficientů determinace při stanovení optimální předpovědi vzad	36
Tab. 4 Porovnání sum koeficientů determinace při stanovení vhodného počtu vstupních měsíců vzad	43
Tab. 5 Výpis jednotlivých sum koeficientů determinace pro danou délku předpovědi vpřed.....	44
Tab. 6 Porovnání průměrných sum koeficientů determinace při stanovení optimální délky předpovědi vpřed....	45
Tab. 7 Výpočet sum koeficientů determinace při stanovení optimální předpovědi vzad	46
Tab. 8 Porovnání sum koeficientů determinace při stanovení vhodného počtu vstupních měsíců vzad	47
Tab. 9 Výpis jednotlivých sum koeficientů determinace pro danou délku předpovědi vpřed.....	48
Tab. 10 Porovnání průměrných sum koeficientů determinace při stanovení optimální délky předpovědi vpřed..	49
Tab. 11 Porovnání naměřených a předpovězených průměrných měsíčních průtoků pro měrný profil Dalečín....	50
Tab. 12 Porovnání naměřených a předpovězených průměrných měsíčních průtoků pro měrný profil Skryje.....	56
Tab. 13 Porovnání průtoků předpovězených klasickým a hybridním předpovědním modelem neuronových sítí	63
Tab. 14 Porovnání předpovědních modelů pomocí odchylek mezi předpovídanými průtoky	69
Tab. 15 Porovnání předpovězených průtoků klasickým modelem neuronových sítí a modelem typu ARMA v měrném profilu Dalečín.....	70
Tab. 16 Porovnání předpovězených průtoků klasickým modelem neuronových sítí a modelem typu ARMA v měrném profilu Skryje.....	72
Tab. 17 Porovnání předpovědních modelů pomocí odchylek mezi předpovídanými průtoky pro měrný profil Dalečín.....	74
Tab. 18 Porovnání předpovědních modelů pomocí odchylek mezi předpovídanými průtoky pro měrný profil Skryje.....	74
Tab. 19 Porovnání předpovědních modelů pomocí koeficientů determinace	75

SEZNAM PŘÍLOH

Příloha č.1: CD obsahující výpočty ve formátu .xlsx